

UNIVERSIDADE FEDERAL DO PARANÁ

LUCAS COSTA CICARELLI

**CLASSIFICAÇÃO DE VEÍCULOS AUTOMOTIVOS PELO PERFIL
MAGNÉTICO EM LAÇOS INDUTIVOS**

CURITIBA

2011

LUCAS COSTA CICARELLI

**CLASSIFICAÇÃO DE VEÍCULOS AUTOMOTIVOS PELO PERFIL
MAGNÉTICO EM LAÇOS INDUTIVOS**

Dissertação apresentada como requisito parcial à obtenção do grau de Mestre, no Programa de Pós-Graduação em Engenharia Elétrica, Setor de Tecnologia, Universidade Federal do Paraná – UFPR

Orientador: Prof. Dr. Eduardo Parente Ribeiro

CURITIBA

2011

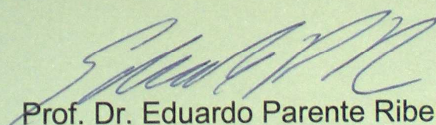
TERMO DE APROVAÇÃO

LUCAS COSTA CICARELLI

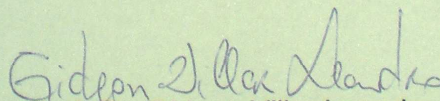
CLASSIFICAÇÃO DE VEÍCULOS AUTOMOTIVOS PELO PERFIL MAGNÉTICO EM LAÇOS INDUTIVOS

Dissertação aprovada como requisito parcial para a obtenção do grau de Mestre no Curso de Pós-Graduação em Engenharia Elétrica, Setor de Tecnologia da Universidade Federal do Paraná, pela seguinte banca examinadora:

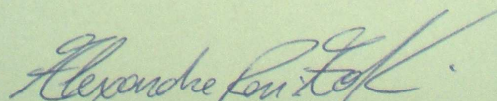
Orientador:



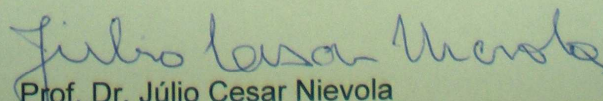
Prof. Dr. Eduardo Parente Ribeiro
Departamento de Engenharia Elétrica, UFPR



Prof. Dr. Gideon Villar Leandro
Departamento de Engenharia Elétrica, UFPR



Prof. Dr. Alexandre Rasi Aoki
Departamento de Engenharia Elétrica, UFPR



Prof. Dr. Júlio Cesar Nievola
Programa de Pós-Graduação em Informática, PUCPR

Curitiba, 19 de Dezembro de 2011.

AGRADECIMENTOS

Primeiramente a Deus, que me tem dado vida, respiração e tudo o mais.

Ao meu orientador, Professor Eduardo, pelo incentivo e direcionamento ao longo desta jornada.

À empresa Perkons S/A, em nome do Engenheiro Leandro Becker, pela disponibilização da base de dados coletadas para realização deste trabalho.

À minha amada esposa Reneè, pelo carinho, amor e compreensão, ao privar-se de meu convívio em diversos momentos para que eu pudesse realizar esta pesquisa.

Aos meus pais, que me ensinaram o caminho do bem, me propiciaram um lar de amor e acreditaram e investiram em mim tempo, dedicação e todos os recursos necessários para minha formação.

E a todos os colegas e familiares amigos que de alguma forma contribuíram com ideias, sugestões e críticas para este trabalho.

RESUMO

A identificação da categoria de um veículo que trafega em uma via é um importante parâmetro para sistemas de gerenciamento de tráfego. A classificação veicular tem aplicações como planejamento do sistema viário, estimativa de emissões veiculares e fiscalização de tráfego. Várias técnicas são empregadas para realizar a tarefa de classificação de veículos, sendo que a maioria processa informações provenientes dos sensores indutivos. Neste trabalho, é avaliado um sistema para classificação de veículos tanto em seis categorias, como em oito categorias. O sistema utiliza rede neural perceptron multicamada (*Multi-Layer Perceptron* - MLP) e é comparado com outras técnicas lineares de classificação como as medidas de similaridade Distância Euclidiana e Distância de Mahalanobis. As variáveis de entrada utilizadas para a rede neural foram extraídas a partir dos perfis magnéticos adquiridos. Este estudo apresenta uma análise da seleção dos parâmetros de entrada para a classificação. O sistema avaliado foi capaz de alcançar índices de acerto na classificação de 97% em seis categorias e 90% em oito categorias. Os resultados dos testes mostram a viabilidade técnica de se utilizar o sistema em equipamentos fixo de fiscalização eletrônica, permitindo a diferenciação de categorias muito semelhantes entre si como, por exemplo, caminhonetes de camionetas.

Palavras-chave: Classificação de veículos. Redes neurais. Sensores indutivos. Medidas de similaridade.

ABSTRACT

Vehicle class is an important parameter in the process of road-traffic measurement. Vehicle classification is applied in roadway design, vehicle emissions management and traffic monitoring. Several techniques are employed to perform the classification task. Most of them process information from the inductive sensors. In this paper the author suggests a system to classifying vehicles into six categories and a system to classifying vehicles into eight categories. The system has been developed using multilayer perceptron neural network (Multi-Layer Perceptron - MLP) and it is compared with other linear classification techniques such as the similarity measures Euclidean and Mahalanobis distance. The input variables are obtained from the magnetic profiles acquired from inductive loops. This study presents the methodology to select the input parameters to the classification. It is shown that this system is able to achieve rates of correct classification of nearly 97% with six categories and 90% with eight categories and it can be used in a fixed traffic monitoring equipment allowing the differentiation of categories very closed to each other as pickups and small utility vehicles.

Keywords: Vehicle classification. Neural Network. Inductive Sensors, Similarity Measures

LISTA DE FIGURAS

| | |
|--|----|
| Figura 1 - Diagrama do Sistema Detector (NISHIMOTO, 2006)..... | 14 |
| Figura 2 – Foto e perfil magnético de: (a) Carro, (b) Ônibus, (c) Moto, (d) Caminhão, (e) Carreta, (f) Caminhonete, (g) Van, (h) Camioneta. | 17 |
| Figura 3 - Extração de características do perfil magnético (RITCHIE <i>et al</i> , 2005a). . | 19 |
| Figura 4 - Características do Perfil Magnético Normalizado (RITCHIE <i>et al</i> , 2008). . | 20 |
| Figura 5 – Vetores de características em espaço bidimensional (DIAS, 2004). | 24 |
| Figura 6 - Distância de Mahalanobis para localização de <i>outlier</i> (ACKLAM, 2000)... | 25 |
| Figura 7 - Modelo Matemático do Neurônio. | 27 |
| Figura 8 - Função de Limiar | 28 |
| Figura 9 - Função de Limiar por partes. | 28 |
| Figura 10 - Função Sigmoidal. | 29 |
| Figura 11 - Função Tangente Hiperbólica. | 29 |
| Figura 12 - Distribuição do comprimento magnético dos veículos entre as oito categorias. | 47 |
| Figura 13 - Perfis característicos das diferentes categorias. | 48 |
| Figura 14 - Distribuição das amostras em um espaço tridimensional (Número de Pontos X Valor Médio X Número de Máximos e Mínimos) | 49 |
| Figura 15 - Estrutura da rede MLP (<i>Multi-layer Perceptron</i>) sendo x o vetor de entradas e y o vetor das saídas..... | 50 |
| Figura 16 - Distribuição da Amplitude Máxima para as oito categorias..... | 78 |
| Figura 17 - Valor médio distribuído entre as oito categorias. | 79 |
| Figura 18 - Distribuições do número de picos para as oito categorias. | 79 |
| Figura 19 - Distribuição do valor médio de picos entre as oito categorias | 80 |
| Figura 20 - Distribuição estatística da variância normalizada para as oito categorias | 81 |
| Figura 21 - Distribuição estatística da taxa de subida normalizada para as oito categorias | 81 |
| Figura 22 - Distribuição estatística do Grau de Simetria para as oito categorias. | 82 |
| Figura 23 - Distribuição estatística da Mediana para as oito categorias. | 82 |
| Figura 24 – O número de amostras de alta amplitude (NHM) possibilita uma importante separação das vans em relação a caminhonetes e camionetas..... | 83 |

Figura 25 - Distribuição estatística do Parâmetro de Forma para as oito categorias.83

Figura 26 - a) Carro, b) Ônibus, c) Moto, d) Caminhão, e) Van, f) Caminhonete, g) Camionetas, h) Carreta.87

Figura 27 - Perfis magnéticos e perfil característico do grupo de carretas do tipo 1 (a) e do tipo 2 (b). As carretas do Tipo 1 têm carroceria com predomínio de material não metálico, e portanto, a amplitude máxima do perfil é determinada pela parte do cavalo mecânico, sendo atingido o máximo enquanto esta parte passa por sobre os sensores. Já as acarretas do Tipo 2, apresentam carroceria com grande composição metálica, como é o caso da carreta “cegonha”. Assim a amplitude máxima do perfil é maior, sendo o valor mínimo atingido no momento da passagem da carroceria por sobre o sensor, pelo fato de esta parte encontrar-se mais baixa em relação ao asfalto.87

SUMÁRIO

| | | |
|-------------------------|---|-----------|
| AGRADECIMENTOS | | 13 |
| RESUMO | 14 | |
| ABSTRACT | 15 | |
| LISTA DE FIGURAS | | 16 |
| 1 | INTRODUÇÃO | 10 |
| 1.1 | CONTEXTO..... | 10 |
| 1.2 | OBJETIVOS | 10 |
| 1.2.1 | OBJETIVO GERAL..... | 10 |
| 1.2.2 | OBJETIVOS ESPECÍFICOS | 11 |
| 1.3 | ESTRUTURA DA DISSERTAÇÃO | 11 |
| 2 | FUNDAMENTAÇÃO | 13 |
| 2.1 | SENSOR INDUTIVO | 13 |
| 2.2 | SISTEMA DETECTOR VEICULAR | 14 |
| 2.2.1 | PERFIL MAGNÉTICO | 15 |
| 2.3 | EXTRAÇÃO DE CARACTERÍSTICAS DO PERFIL MAGNÉTICO | 18 |
| 2.3.1 | COMPRIMENTO MAGNÉTICO DO VEÍCULO..... | 20 |
| 2.3.2 | AMPLITUDE MÁXIMA | 21 |
| 2.3.3 | VALOR MÉDIO..... | 21 |
| 2.3.4 | NÚMERO DE PICOS..... | 21 |
| 2.3.5 | VALOR MÉDIO DE PICOS..... | 21 |
| 2.3.6 | VARIÂNCIA NORMALIZADA | 22 |
| 2.3.7 | TAXA DE SUBIDA NORMALIZADA | 22 |
| 2.3.8 | MEDIANA | 22 |
| 2.3.9 | GRAU DE SIMETRIA | 22 |
| 2.3.10 | NÚMERO DE AMOSTRAS DE ALTA AMPLITUDE | 23 |
| 2.3.11 | PARÂMETRO DE FORMA..... | 23 |
| 2.4 | MEDIDAS DE SIMILARIDADE | 23 |
| 2.4.1 | DISTÂNCIA EUCLIDIANA | 23 |

| | | |
|----------|---|-----------|
| 2.4.2 | DISTÂNCIA EUCLIDIANA NORMALIZADA | 24 |
| 2.4.3 | DISTÂNCIA DE MAHALANOBIS..... | 25 |
| 2.5 | REDES NEURAS | 26 |
| 2.5.1 | FUNÇÃO DE LIMIAR..... | 27 |
| 2.5.2 | FUNÇÃO LIMIAR POR PARTES..... | 28 |
| 2.5.3 | FUNÇÃO SIGMOIDAL..... | 29 |
| 2.5.4 | FUNÇÃO TANGENTE HIPERBÓLICA | 29 |
| 2.5.5 | REDE NEURAL PERCEPTRON MULTICAMADA | 30 |
| 2.5.6 | TREINAMENTO COM LEVENBERG-MARQUARDT | 31 |
| 2.5.7 | TREINAMENTO COM REGULARIZAÇÃO BAYESIANA | 31 |
| 2.5.8 | TREINAMENTO COM GRADIENTE CONJUGADO E MOMENTO..... | 32 |
| 2.5.9 | PARADA ANTECIPADA DO TREINAMENTO..... | 33 |
| 3 | TRABALHOS RELACIONADOS | 35 |
| 4 | MÉTODO | 45 |
| 4.1 | COMPRIMENTO MAGNÉTICO..... | 46 |
| 4.2 | MÚLTIPLOS PERFIS | 47 |
| 4.2.1 | REDE NEURAL: TREINAMENTO, FLUXOGRAMAS, ARQUITETURA DA REDE NEURAL E TREINAMENTO | 49 |
| 4.2.2 | TREINAMENTO COM LEVENBERG MARQUARDT | 54 |
| 4.2.3 | TREINAMENTO COM PARADA ANTECIPADA..... | 54 |
| 4.2.4 | TREINAMENTO COM REGULARIZAÇÃO BAYESIANA | 54 |
| 4.2.5 | TREINAMENTO COM GRADIENTE CONJUGADO E MOMENTO..... | 54 |
| 4.3 | REDES NEURAS EM TOPOLOGIA 1 DE N | 55 |
| 4.4 | DISTÂNCIA EUCLIDIANA..... | 56 |
| 4.5 | DISTÂNCIA EUCLIDIANA NORMALIZADA | 57 |
| 4.6 | DISTÂNCIA DE MAHALANOBIS..... | 57 |
| 5 | RESULTADOS | 58 |
| 5.1 | CLASSIFICAÇÃO EM SEIS CATEGORIAS | 58 |
| 5.1.1 | SEIS CATEGORIAS – REDE NEURAL – TRÊS PARÂMETROS – COMPRIMENTO MAGNÉTICO, MÁXIMA AMPLITUDE E NÚMERO DE PICOS | 58 |
| 5.1.2 | 6 CATEGORIAS – REDE NEURAL – 11 PARÂMETROS..... | 60 |
| 5.1.3 | SEIS CATEGORIAS – DISTÂNCIA DE MAHALANOBIS | 61 |

| | | |
|-----------------|--|-----------|
| 5.2 | CLASSIFICAÇÃO EM OITO CATEGORIAS | 62 |
| 5.2.1 | 11 PARÂMETROS..... | 62 |
| 5.2.2 | 1_N REDES NEURAS..... | 64 |
| 5.2.3 | DISTÂNCIA DE MAHALANOBIS – 11 PARÂMETROS..... | 65 |
| 5.2.4 | DISTÂNCIA DE MAHALANOBIS – TRÊS PARÂMETROS | 66 |
| 5.3 | CLASSIFICAÇÃO DE UTILITÁRIOS..... | 67 |
| 5.3.1 | SOMENTE UTILITÁRIOS – DISTÂNCIA DE MAHALANOBIS | 68 |
| 5.3.2 | SOMENTE UTILITÁRIOS – REDE NEURAL | 69 |
| 5.4 | RESUMO DOS RESULTADOS..... | 70 |
| 6 | CONCLUSÃO | 72 |
| | REFERÊNCIAS BIBLIOGRÁFICAS | 74 |
| ANEXO I | 78 | |
| | DISTIBUIÇÃO ESTATÍSTICA DOS PARÂMETROS EXTRAÍDOS DO PERFIL MAGNÉTICO PARA A BASE DE DADOS DE VEÍCULOS | 78 |
| 6.1 | AMPLITUDE MÁXIMA | 78 |
| 6.2 | VALOR MÉDIO..... | 79 |
| 6.3 | NÚMERO DE PICOS..... | 79 |
| 6.4 | VALOR MÉDIO DE PICOS..... | 80 |
| 6.5 | VARIÂNCIA NORMALIZADA | 80 |
| 6.6 | TAXA DE SUBIDA..... | 81 |
| 6.7 | GRAU DE SIMETRIA | 82 |
| 6.8 | MEDIANA | 82 |
| 6.9 | NÚMERO DE AMOSTRAS DE ALTA AMPLITUDE | 83 |
| 6.10 | PARÂMETRO DE FORMA..... | 83 |
| ANEXO II | 85 | |
| | COMPARAÇÃO ENTRE PERFIS CARACTERÍSTICOS | 85 |

1 INTRODUÇÃO

1.1 CONTEXTO

A classificação de veículos automotores em diferentes categorias apresenta grande utilidade para sistemas inteligentes de tráfego - ITS (*Intelligent Traffic Systems*). Os ITSs contribuem com ferramentas para a gestão do trânsito em diversas aplicações como comunicação, sinalização, organização, gerenciamento, controle e proteção dos agentes (pedestres, veículos, estradas, etc.) envolvidos – sobretudo os humanos. Um sistema capaz de classificar veículos em diferentes categorias contribui com os ITSs em tarefas como:

- Planejar o sistema viário;
- Estimar a emissão de poluentes nas vias;
- Verificar a sazonalidade do tráfego, ou seja, as mudanças de comportamento do mesmo em épocas distintas;
- Localizar e projetar pontos de instalações para as operações de monitoramento e fiscalização;
- Fiscalizar vias que permitam o tráfego exclusivo de categorias de veículos;
- Fiscalizar categorias de veículos distintas em faixas de velocidades distintas.

A maior parte dos sistemas de classificação utilizados tem como base o processamento das variáveis obtidas dos sensores indutivos. Eles são amplamente difundidos como elemento sensor em equipamentos fixos de fiscalização eletrônica pelas vantagens apresentadas em termos de custo e confiabilidade (CALIXTO, 2006)

1.2 OBJETIVOS

1.2.1 OBJETIVO GERAL

Este trabalho objetiva-se primordialmente propor ferramentas para caracterização e identificação de categorias de veículos automotores. Para realizar esta tarefa, foram utilizadas redes neurais perceptron multicamada (MLP) tendo como variáveis de entrada os parâmetros extraídos a partir das respostas produzidas pelos sensores indutivos durante a passagem dos diferentes veículos sobre os mesmos. Para o treinamento da rede foram utilizados os algoritmos

Levenberg-Marquardt, Regularização Bayesiana, Parada Antecipada e Gradiente Conjugado com Momento. Foram testadas diferentes combinações de variáveis de entrada para a rede neural. Os resultados dos diferentes casos foram comparados em relação aos índices de classificação correta obtidos.

1.2.2 OBJETIVOS ESPECÍFICOS

O estudo busca avaliar o sistema de classificação quanto a:

- Capacidade para classificar veículos levando em consideração seu perfil magnético e a variação provocada nos sensores indutivos,
- Extração de características relevantes dos perfis magnéticos
- Resultados apresentados na classificação veicular em relação a métodos lineares como medidas de similaridade

O algoritmo de classificação do sistema proposto realiza a separação entre caminhonetes, camionetas e vans o que poderia contribuir com o agente de trânsito na diferenciação dos veículos que possuem velocidades máximas regulamentadas, visto que o código de trânsito brasileiro (CTB) regulamenta diferentes velocidades em vias expressas para caminhões e caminhonetes (80 km/h), ônibus (90 km/h) e veículos de passeio ou motos (110 km/h) (Art. 61, Código de Trânsito Brasileiro, 1997). Segundo o artigo 96 do CTB, Caminhonete (*pickup*) é todo veículo destinado ao transporte de carga com peso bruto total de até 3,5 mil kg (passageiros e carga em compartimentos separados). Já camioneta é um veículo misto destinado ao transporte de passageiros e carga no mesmo compartimento, também conhecida como SUV, do inglês *Small Utility Vehicle*.

1.3 ESTRUTURA DA DISSERTAÇÃO

A estrutura desta dissertação está dividida em seis capítulos, sendo o primeiro, o capítulo introdutório. No capítulo 2 é feita uma apresentação sobre os conceitos relacionados à detecção veicular através de sensores indutivos, medidas de similaridade aplicadas à classificação. O capítulo aborda também os aspectos gerais sobre a técnica de inteligência artificial das redes neurais. No capítulo 3, são apresentados outros trabalhos relacionados sobre classificação veicular através de sensores indutivos, sensores baseados em imagem, sensores acústicos e sensores magnéticos. Os capítulos 2 e 3 compõem a fundamentação teórica para o trabalho.

O capítulo 4 faz uma apresentação da metodologia utilizada no trabalho, descrevendo os diferentes casos de testes e os procedimentos para extração de características relevantes do perfil magnético e as técnicas utilizadas. Os resultados dos testes são mostrados no capítulo 5, onde também são feitas as análises desses resultados. Por último, o capítulo 6 mostra as considerações finais e a conclusão.

2 FUNDAMENTAÇÃO

2.1 SENSOR INDUTIVO

O sensor ou laço indutivo é basicamente uma bobina de cabo metálico excitada por uma corrente alternada. Segundo a Lei de Ampère, a corrente alternada aplicada à bobina gera um campo magnético em torno dela. Dessa forma, quando algum objeto condutor (massa metálica) invade o campo magnético da bobina, correntes elétricas de baixa intensidade são induzidas na superfície condutiva deste objeto. Segundo a Lei de Lenz, essas correntes geram um campo magnético que atuam em oposição ao campo magnético gerado pela bobina do sensor. Essa oposição altera a frequência de ressonância da bobina, reduzindo sua indutância externa. O circuito eletrônico que monitora os laços indutivos pode captar duas variações: o aumento na frequência de ressonância ou a diminuição na amplitude do sinal sobre o laço, ambas proporcionais à variação de indutância externa dos laços, atuando, portanto como um detector de massas metálicas (FHWA, 1990).

Os detectores de metais são amplamente utilizados para localizar objetos metálicos que estão enterrados ou escondidos tendo aplicação em uso militar, prospecção geológica e exploração arqueológica. Apresentam também utilização industrial como sensoriamento de posição e inspeção automatizada dos processos de manufatura, montagem e embalagem. Os sensores são também os componentes ativos em sistemas de segurança de aeroportos e bancos, de forma a detectar a presença de objetos metálicos, de forma a prevenir o ingresso de pessoas armadas. Detectores de laço indutivo são também instalados em rodovias e cruzamentos para monitoramento e controle de tráfego, bem como em estacionamentos para controle de vagas e de acesso (HILLIARD e HILLIARD, 2002).

O sensoriamento indutivo para veículos automotores vem sendo utilizado há mais de 30 anos em todo o mundo em aplicações de sistemas inteligentes de transporte (ITS), fiscalização eletrônica de velocidade e outras aplicações comerciais (NISHIMOTO, 2006).

O uso de sensores indutivos também já foi aplicado em Tomografia por Indução Magnética (MIT, do inglês *Magnetic Induction Tomography*). O objetivo desta técnica é a obtenção de imagens da distribuição de condutividade elétrica de

um objeto a partir da medição da perturbação causada pelas correntes induzidas por um campo magnético externo aplicado (PARENTE, 1996),(RÜNCOS, 2007).

2.2 SISTEMA DETECTOR VEICULAR

O sistema de detecção de veículos presente nos equipamentos do tipo DEV (Detector Eletrônico de Velocidade) utilizados neste trabalho, consiste em um sistema embarcado, constituído de filtros de hardware e software, amplificadores de sinal, sendo baseado em arquitetura DSP (*Digital Signal Processor*). O funcionamento do sistema de fiscalização se resume em detectar a passagem do veículo, fazer o cálculo e a conferência da velocidade e, se verificada a infração, capturá-lo através do sistema de vídeo. Quando um veículo transita sobre os sensores indutivos, é gerado um perfil magnético dependente de sua velocidade, dimensões e distribuição de massa metálica que o compõe ao longo de seu comprimento (NISHIMOTO, 2006). A Figura 1 apresenta o diagrama em blocos do sistema detector utilizado para obtenção da resposta do sensor na forma de perfil magnético.




Figura 1 - Diagrama do Sistema Detector (NISHIMOTO, 2006).


Inicialmente, o sinal do laço indutivo passa por um filtro passa-faixa (FPF) que elimina as frequências capturadas fora do espectro de trabalho do sistema detector. Em seguida, o sinal passa por um transformador que isola o laço instalado no asfalto, da eletrônica da placa detectora, elevando o sinal através da relação de 16:1 das bobinas. O sinal é então amplificado eletronicamente e passa por um filtro passa-baixa (FPB) em 10 Hz, que elimina frequências indesejadas permitindo que chegue ao conversor A/D somente a variação do perfil magnético do veículo. O sinal é digitalizado no conversor analógico-digital de 12 bits que resulta no perfil magnético. Após a conversão analógico-digital, o perfil magnético passa por alguns

filtros digitais para tratamento e condicionamento do sinal, eliminando ruídos da rede elétrica e de alta frequência. (NISHIMOTO, 2006).


2.2.1 PERFIL MAGNÉTICO

O Perfil Magnético de um objeto metálico consiste na variação da indutância externa de um sensor indutivo ao longo do tempo, devido à interação do campo magnético gerado pelo laço indutivo com a massa metálica do objeto em movimento (HILLIARD e HILLIARD, 2002). É também conhecido como assinatura magnética do objeto.


Na Figura 2 são mostradas algumas imagens representativas de veículos, coletadas nos equipamentos de fiscalização eletrônica em conjunto com os respectivos perfis magnéticos extraídos.




(a)




(b)




(c)




(d)




(e)



(f)



(g)



(h)

Figura 2 – Foto e perfil magnético de: (a) Carro, (b) Ônibus, (c) Moto, (d) Caminhão, (e) Carreta, (f) Caminhonete, (g) Van, (h) Camioneta.

2.3 EXTRAÇÃO DE CARACTERÍSTICAS DO PERFIL MAGNÉTICO

Diversas características podem ser obtidas a partir do processamento da assinatura magnética obtida do sensor indutivo. Tais características podem ser divididas em duas categorias: aquelas que são específicas do veículo e aquelas que são específicas do tráfego. As características do veículo representam os elementos únicos do veículo e, portanto são invariantes ao longo do tempo ou localização. Um exemplo é o comprimento veicular (MAGALHÃES, 2008). Em contrapartida, as características relacionadas ao tráfego dependem das condições da via e do fluxo de veículos, como a velocidade e o tempo de ocupação do veículo sobre o laço. O primeiro passo para extração de características é a normalização da amplitude. A normalização ajuda a identificar a presença do veículo, restaurando a assinatura válida, distinguindo-a do ruído.

Podem ser extraídas determinadas características do perfil magnético, as quais em conjunto permitem diferenciar uma classe de veículo de outra, sendo que os modelos de cada categoria apresentam perfis magnéticos semelhantes (CALIXTO, 2006). Neste capítulo são apresentadas as principais características e o método de obtenção de cada uma delas. O sistema proposto neste trabalho classifica veículos em oito categorias: carro, moto, ônibus, caminhão, carreta, caminhonete, camioneta e van.

Uma vez que se sabe a velocidade de cada veículo, tendo sido esta calculada através de dois sensores indutivos instalados em distância fixa, pode-se eliminar a dependência deste parâmetro, normalizando-se o perfil ao longo do tempo. As diferenças construtivas dos laços indutivos, bem como dos parâmetros de ajuste e *offset*, são corrigidas, normalizando a amplitude dos sinais magnéticos obtidos.

Para se obter o perfil magnético normalizado em amplitude, dividem-se os valores correspondentes ao eixo das ordenadas y pela máxima amplitude do perfil (A). Para a normalização em relação ao comprimento magnético, multiplica-se o tempo de ocupação (t) pela velocidade do veículo (Figura 3) (RITCHIE *et al*, 2005a).

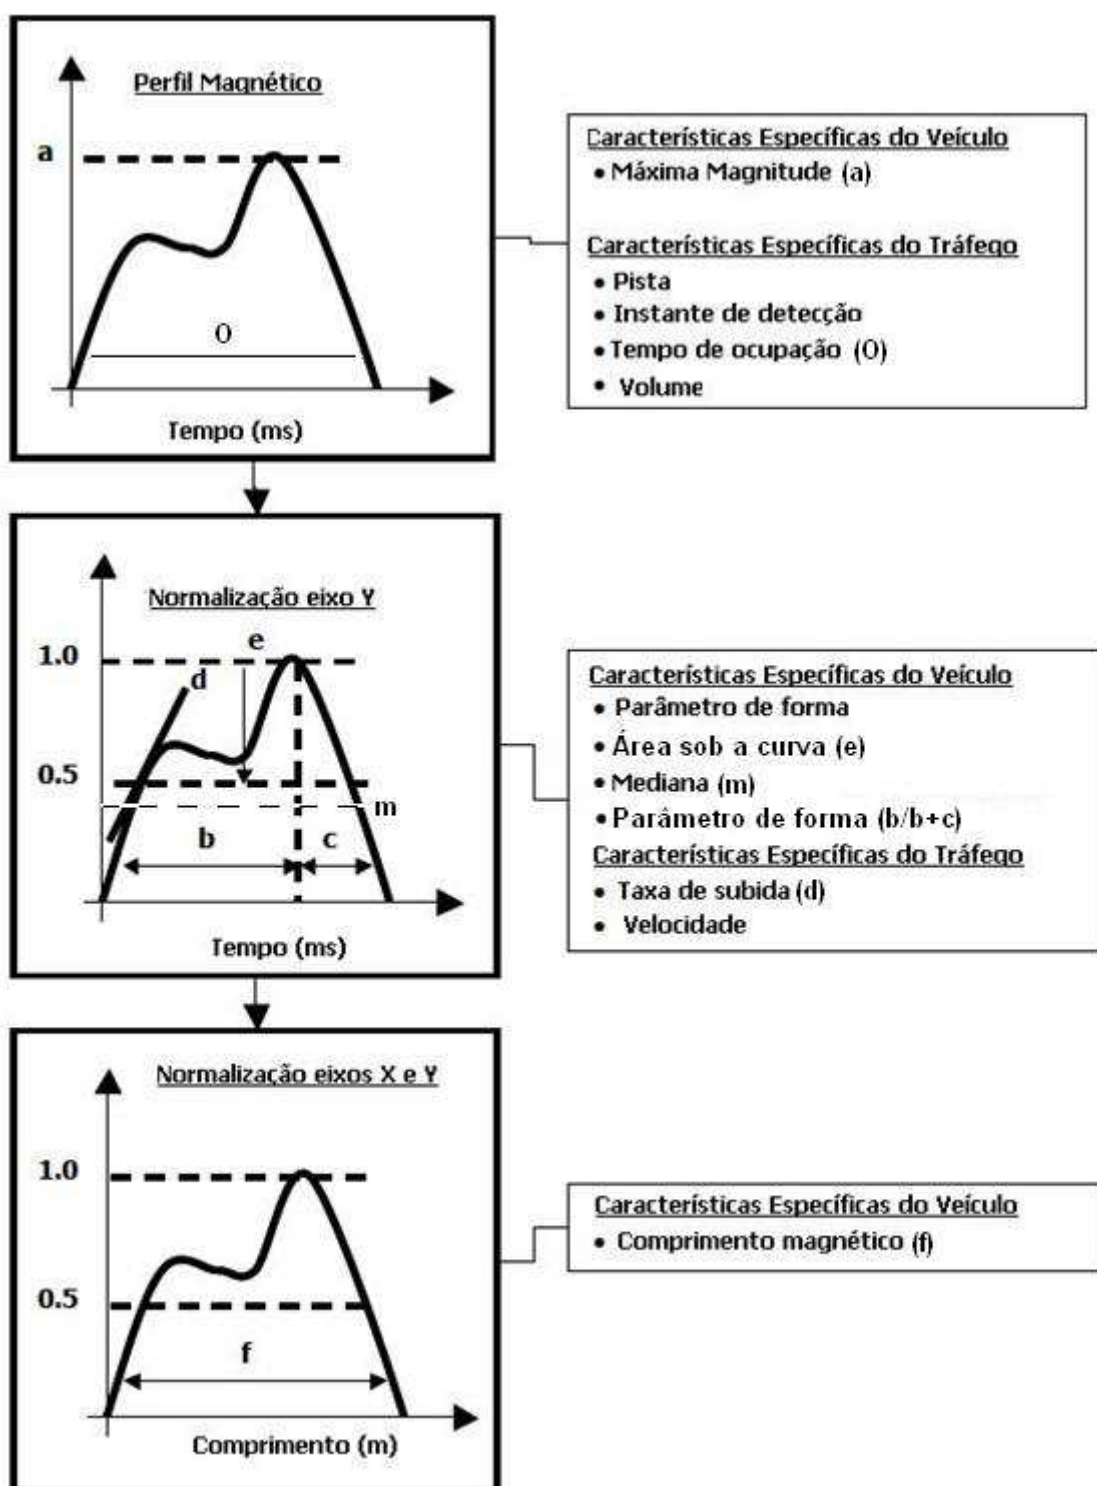


Figura 3 - Extração de características do perfil magnético (RITCHIE *et al*, 2005a).

A Figura 4 mostra a curva de perfil magnético normalizadas no eixo horizontal (comprimento) e vertical (amplitude) para um veículo do tipo caminhão (RITCHIE *et al*, 2008). Para realizar a classificação utilizaram-se somente as

curvas geradas a partir de um dos laços indutivos, uma vez que a informação provida a partir do segundo laço é praticamente a mesma que a do primeiro, não sendo necessária para a análise do problema.

As curvas de perfis magnéticos apresentam características similares referentes a cada categoria de veículos. O perfil magnético de um veículo de passeio tem o formato de uma parábola. Ônibus e caminhões apresentam formatos com maiores ondulações. O perfil de uma van se assemelha a de um veículo de passeio, porém é mais largo na base da parábola. O formato da curva depende do chassi, comprimento do veículo e configuração de eixos (KI e BAIK, 2006).




Figura 4 - Características do Perfil Magnético Normalizado (RITCHIE *et al*, 2008).

A seguir serão detalhadas as principais características extraídas do perfil magnético.

2.3.1 COMPRIMENTO MAGNÉTICO DO VEÍCULO

O comprimento magnético é calculado através do tempo de ocupação do veículo sobre os sensores e a velocidade que o veículo passa sobre os mesmos (CALIXTO, 2006). É calculado pela equação (1):

$$s = v.t - d \quad (1)$$

Onde s é o comprimento magnético do veículo (m), v a velocidade do veículo (m/s), d a largura do sensor indutivo (m) e t o tempo (s) que o sensor fica ativo por influência do veículo.

2.3.2 AMPLITUDE MÁXIMA

A amplitude máxima corresponde ao pico positivo máximo do perfil magnético em relação ao estado estacionário. Na Figura 4 é representado pelo valor A.

A variação de indutância no laço indutivo é inversamente proporcional a distância entre a plataforma do veículo e o sensor. Desse modo, os ônibus e caminhões, por exemplo, produzem uma variação de indutância menor que um veículo de passageiro, que apresenta maior amplitude no perfil magnético.

2.3.3 VALOR MÉDIO

O valor médio (\bar{X}) consiste na somatória das amostras de perfil magnético (x_i) dividido pelo número de pontos do perfil (n), sendo, portanto uma grandeza adimensional. A quantidade de pontos do perfil magnético é função da velocidade do veículo e do seu comprimento magnético (MAGALHÃES, 2008). O valor médio, que é a amplitude do sinal elétrico do perfil magnético, varia proporcionalmente às orientações dos veículos e da posição destes em relação aos sensores.

Desta forma, são observados diferentes valores médios para as categorias. A expressão do cálculo para obtenção deste parâmetro é obtida pela equação (2):

$$\bar{X} = \frac{\sum_{i=1}^n X_i}{n} \quad (2)$$

2.3.4 NÚMERO DE PICOS

O número de picos ou inversões é o total de inflexões na curva de perfil magnético, ou seja, quantas vezes a derivada primeira passa de valor negativo para positivo ou vice-versa, sendo uma grandeza adimensional (CALIXTO, 2006).

2.3.5 VALOR MÉDIO DE PICOS

O valor médio de picos é obtido através dos valores médios dos pontos (X_j) onde estão as inversões no perfil magnético, sendo portanto uma grandeza adimensional. O cálculo para obtenção do parâmetro é dado pela equação (3):

$$\bar{X}_p = \frac{\sum_{j=1}^{ni} X_j}{ni} \quad (3)$$

Onde \bar{X}_p é o valor médio das inversões do perfil magnético, X_j o valor do perfil magnético na inversão j e n_i o número de inversões ocorridas no perfil magnético (CALIXTO, 2006).

2.3.6 VARIÂNCIA NORMALIZADA

A variância é uma medida da variabilidade dos dados em torno da média. É definida como o desvio quadrático médio em relação ao valor médio, sendo uma grandeza adimensional. É calculada de acordo com a equação (4):

$$\text{Var} = \sqrt{\frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n-1}} \quad (4)$$

A variância Var é obtida a partir de X_i (valor do perfil magnético normalizado em amplitude e comprimento no ponto i , \bar{X} (valor médio do perfil magnético normalizado em amplitude e comprimento) e n (número de pontos do perfil magnético) (CALIXTO, 2006).

2.3.7 TAXA DE SUBIDA NORMALIZADA

A taxa de subida normalizada é a inclinação do perfil magnético no ponto de ordenada $y=A/2$. Tem como unidade $[(\Delta L/L)/m = m^{-1}]$. Na Figura 4 é representado por “d” (MAGALHÃES, 2008 *apud* OH *et al*, 2002 RITCHIE *et al* 2005b).

2.3.8 MEDIANA

A mediana é definida como o valor que divide os dados ordenados ao meio, isto é metade dos dados têm valores maiores do que a mediana e a outra metade tem valores menores do que a mediana.

2.3.9 GRAU DE SIMETRIA

Seja m a mediana do perfil, o grau de simetria é a soma das distâncias (em y) até m (mediana) de cada ponto e_i acima da ordenada $y = A/2$ (Figura 4). É expresso em $[\Delta L/L]$ sendo, portanto adimensional. O cálculo é feito pela equação (5):

$$\sum_{i=1}^M (e_i - m) \quad (5)$$

Sendo M o total de pontos cuja ordenada seja superior a $A/2$.

2.3.10 NÚMERO DE AMOSTRAS DE ALTA AMPLITUDE

Na Figura 4 é o número de amostras acima da ordenada y de valor igual a A/2, sendo, portanto adimensional.

2.3.11 PARÂMETRO DE FORMA

O parâmetro de forma está relacionado ao grau de simetria e obliquidade do perfil, sendo grandeza adimensional. É calculado por $b/(b+c)$, conforme Figura 4.

2.4 MEDIDAS DE SIMILARIDADE

Classificar um padrão desconhecido, dado um conjunto de classes conhecidas, é um problema fundamental em reconhecimento de padrões.

O classificador de distância mínima é um método que consiste em encontrar o padrão de maior similaridade em um conjunto de referências utilizando uma medida de distância, também conhecida como medida de similaridade. Nesta seção são apresentadas as definições das medidas de similaridade utilizadas neste trabalho: Distância Euclidiana, Distância Euclidiana Normalizada e Distância de Mahalanobis.

2.4.1 DISTÂNCIA EUCLIDIANA

Considere-se um sistema em que cada padrão é descrito por um conjunto de características denominado vetor de características. Sendo assim, os padrões e seus representantes (classes) são descritos em um espaço N-Dimensional, onde N é a quantidade de características (DIAS, 2004).

De forma a verificar graficamente o método, será considerado o exemplo hipotético de classificação com três classes W_1 , W_2 e W_3 , descritas respectivamente pelos vetores de protótipo (médio) m_1 , m_2 , m_3 :

$$m_j = \frac{1}{N_j} \sum_{V \in W_j} V \quad (6)$$

Onde $j = 1, 2, \dots, M$;

N_j é o número de vetores de padrões (V) da classe W_j sendo a soma realizada sobre esses vetores.

M é o número de classes.

O vetor x é um padrão a ser classificado, representado por um vetor de características:

$$x = [X_1, X_2]$$

Adotando como medida de similaridade a distância Euclidiana, tem-se o padrão ' x ' associado a classe j com menor distância $D(x, m_j)$ do vetor de protótipo m_j ao padrão ' x '.

$$D(x, m_j) = \sqrt{\sum_i (x_i - m_{ji})^2} \quad (7)$$

As fronteiras de decisão são definidas como retas perpendiculares ao segmento que liga dois protótipos (classes), sendo que a fronteira intercepta a mediatriz desse segmento, conforme Figura 5.




Figura 5 – Vetores de características em espaço bidimensional (DIAS, 2004).

2.4.2 DISTÂNCIA EUCLIDIANA NORMALIZADA

Como algumas características descrevem uma classe melhor do que outras, torna-se necessário aplicar uma ponderação de modo que estas características tenham mais importância na classificação do que as outras.

A distância euclidiana, quando estimada a partir das variáveis originais, apresenta a inconveniência de ser influenciada pela escala de medida, pelo número de variáveis e pela correlação existente entre as mesmas (VICINI, 2005 *apud* MANLY, 1986).

Para contornar as escalas, faz-se a padronização das variáveis em estudo, para que possuam a variância igual à unidade.

A distância Euclidiana normalizada consiste em ponderar as características com um vetor de pesos, por exemplo, dividindo seus valores pelos respectivos valores da variância.

2.4.3 DISTÂNCIA DE MAHALANOBIS

A distância de Mahalanobis considera a similaridade (medida pela covariância das variáveis) no cálculo da distância. Com esta medida o problema relacionado à escala da distância euclidiana não mais ocorre. Considerando, como exemplo que ao utilizar a distância euclidiana, o conjunto de pontos equidistantes de um certo local formem uma esfera. A distância de Mahalanobis redimensiona a esfera conforme a escala das respectivas variáveis, levando em consideração a correlação entre elas (DWINNELL, 2006).

Uma importante aplicação da distância de Mahalanobis é a localização de valores atípicos (*outliers*). Considerando os dados agrupados no gráfico da Figura 6, o ponto dentro do quadrado vermelho não segue a distribuição apresentada pelo restante dos pontos de dados. Apesar de o ponto não estar no centro de nenhuma das duas escalas (variável 1 e variável 2), existem alguns poucos pontos situados em valores extremos de ambas as variáveis. A distância de Mahalanobis localizaria facilmente este *outlier*.




Figura 6 - Distância de Mahalanobis para localização de *outlier* (ACKLAM, 2000).

A distância de Mahalanobis de um vetor y_j ao conjunto $X = \{x_1, \dots, x_{n_x}\}$ é a distância de y a x_M , o centróide de X , ponderado de acordo com C_x , a matriz de variância do conjunto X , ou seja: (ACKLAM, 2000).

$$d_j^2 = (y_j - x_M)' C_x^{-1} (y_j - x_M) \quad (8)$$

Sendo:

$$x_M = \frac{1}{n_x} \sum_{i=1}^n x_i \quad (9)$$

e

$$C_x = \frac{1}{n_x - 1} \sum_{i=1}^{n_x} (x_i - x_M) (x_i - x_M)' \quad (10)$$

2.5 REDES NEURAIS

Redes Neurais são sistemas computacionais formados por elementos processadores simples, denominados neurônios, altamente interconectados (HAYKIN, 1999). Semelhantemente, ao cérebro humano, o conhecimento adquirido pela Rede Neural ocorre através do processo de aprendizado. Em analogia às sinapses no cérebro humano, as conexões entre os neurônios são utilizadas para armazenar o conhecimento.

As Redes Neurais apresentam as principais características:

- Capacidade de aprender através de exemplos
- Adaptabilidade
- Capacidade de organização
- Capacidade de generalização
- Tolerância a falhas
- Robustez ao ruído

O neurônio é a unidade fundamental de processamento da informação para a rede neural. No modelo matemático do neurônio podem ser destacados três elementos principais, mostrados na Figura 7:

- a) Um conjunto de sinapses, cada uma caracterizada por um peso. Assim um sinal x_j na entrada da sinapse j conectada ao neurônio k , é multiplicado pelo peso sináptico w_{kj} .

- b) Um somador dos sinais de entrada, ponderado pelas respectivas sinapses do neurônio.
- c) Uma função de ativação que limita a amplitude de saída do neurônio.




Figura 7 - Modelo Matemático do Neurônio.

Matematicamente, o modelo é descrito pela equação (11):

$$y_k = \phi(b_k + \sum_{i=1}^m w_{ki}x_i) = \phi(W_k \cdot X) \quad (11)$$

Sendo x_1, x_2, x_m os sinais de entrada; w_{k1}, w_{k2}, w_{km} os pesos sinápticos do neurônio k , b_k o bias, $\phi(\cdot)$ a função de ativação e y_k o sinal de saída do neurônio.

Tal modelo de neurônio apresentado na Figura 7, cuja função de ativação é não linear, aplicada a uma combinação linear (entradas x pesos sinápticos) é chamado de Modelo de McCulloch do Neurônio, ou também Perceptron.

São apresentados os tipos principais de função de ativação.

2.5.1 FUNÇÃO DE LIMIAR

A função de limiar apresenta comportamento semelhante à função degrau, ou seja,

$$\Phi(x) = \begin{cases} 1, & \text{se } x \geq 0 \\ 0, & \text{se } x < 0 \end{cases} \quad (12)$$

Na Figura 8 é apresentado o gráfico correspondente à função.




Figura 8 - Função de Limiar

2.5.2 FUNÇÃO LIMAR POR PARTES

A função limiar por partes é definida pela equação (13):

$$\begin{cases} 1, & \text{se } x \geq 0.5 \\ x + 0.5, & \text{se } -0.5 < x < 0.5 \\ 0, & \text{se } x \leq -0.5 \end{cases} \quad (13)$$

O fator de amplificação está dentro da região linear e é considerado unitário. Na Figura 9 é apresentado o gráfico correspondente a função.




Figura 9 - Função de Limiar por partes.

2.5.3 FUNÇÃO SIGMOIDAL

A função sigmoideal é a mais comum função de ativação utilizada na construção de redes neurais. Apresenta equilíbrio entre o comportamento linear e não linear. É definida pela equação (14):

$$\Phi(x) = \frac{1}{1 + e^{-ax}} \quad (14)$$

Na Figura 10 é mostrado o gráfico correspondente a função.




Figura 10 - Função Sigmoidal.

2.5.4 FUNÇÃO TANGENTE HIPERBÓLICA

A função tangente hiperbólica é dada pela equação (15):

$$\Phi(x) = \tanh(x) \quad (15)$$

Na Figura 11 é mostrado o gráfico correspondente a função.




Figura 11 - Função Tangente Hiperbólica.

2.5.5 REDE NEURAL PERCEPTRON MULTICAMADA

A rede neural perceptron multicamada (MLP) é constituída por um conjunto de unidades sensoriais, que formam a camada de entrada, uma ou mais camadas ocultas de neurônios computacionais e uma camada de saída de neurônios computacionais. O sinal de entrada se propaga na rede de forma direta, através das camadas (HAYKIN, 1999).

Os algoritmos de treinamento (ou aprendizado) de uma MLP têm a característica de ajustar de forma iterativa os pesos das conexões entre os neurônios até que os pares de entradas e saídas esperados, no caso de aprendizado supervisionado, por exemplo, sejam obtidos e as relações matemáticas de causa e efeito possam ser estabelecidas. O método de aprendizado mais utilizado em redes MLP é o algoritmo de retropropagação de erro. Este consiste nos seguintes passos (HAYKIN, 1999):

No primeiro passo, a informação é propagada de forma direta ao longo das camadas da rede, produzindo uma determinada saída, sendo mantidos fixos os pesos sinápticos.

Nos segundo passo, o sinal se propaga de forma reversa ao longo das camadas, sendo atualizados os pesos sinápticos de acordo com a regra para correção de erro. O sinal de erro é produzido pela diferença entre a resposta produzida pela rede e o valor desejado, chamado alvo (*target*).

O algoritmo de retropropagação do erro apresenta uma série de dificuldades ou deficiências que desestimula uma maior disseminação do seu uso. O principal problema diz respeito à lentidão do algoritmo para superfícies mais complexas. Não é raro o algoritmo convergir para mínimos locais. Os mínimos locais são pontos na superfície de erro que apresentam uma solução estável, embora não sejam a saída correta. Desde que o algoritmo de retropropagação de erro foi popularizado algumas pesquisas vêm buscando técnicas tanto para acelerar o algoritmo quanto para reduzir a incidência de mínimos locais. Dentro destas técnicas destaca-se o algoritmo de treinamento de Levenberg-Marquardt (HAGAN e MENHAJ, 1994). Este e outros algoritmos utilizados para treinamento são apresentados nesta seção.

2.5.6 TREINAMENTO COM LEVENBERG-MARQUARDT

O treinamento Levenberg-Marquardt (LM) é uma função que atualiza os pesos e valores dos *bias* de acordo com a otimização Levenberg-Marquardt. O método de LM é usado para encontrar um ponto de mínimo para uma função $F(x)$ dada pela soma dos quadrados de funções não lineares.

No algoritmo LM, as mudanças (Δ) nos pesos \vec{w} são obtidas solucionando:

$$\alpha \Delta = -\frac{1}{2} \nabla E \quad (16)$$

Sendo E , o erro quadrático médio na rede.

$$E = \frac{1}{N} \sum_{k=1}^N [y(x_k) - d_k] \quad (17)$$

Onde N é o número de exemplos $y(x_k)$ é a saída correspondente da rede ao exemplo x_k e d_k é a saída desejada para aquele exemplo. Os elementos da matriz α são dados por:

$$\alpha_{ij} = (1 + \lambda \delta_{ij}) \sum_{r=1}^p \sum_{k=1}^N \left[\frac{\partial y(x_k)}{\partial w_i} \frac{\partial y(x_k)}{\partial w_j} \right] \quad (18)$$

Onde p é o número de saídas da rede. Começando com pesos iniciais aleatórios, ambos α e ∇E são calculados resolvendo a equação (16). A correção para os valores dos pesos é obtida por ($w' = w + \Delta$), conhecido como época de aprendizado LM. Cada iteração com essas épocas reduz o erro até encontrar um mínimo. A variável λ na equação (18) é o parâmetro que é ajustado a cada época de acordo com a evolução do erro (GONÇALVES *et al*, 2010).

2.5.7 TREINAMENTO COM REGULARIZAÇÃO BAYESIANA

O método Bayesiano com regularizações é uma função que atualiza os pesos e valores dos *bias* de acordo com a otimização LM descritas nas Equações 16, 17 e 18. Tipicamente os algoritmos de treinamento têm como objetivo reduzir a soma dos erros quadráticos, entretanto a regularização adiciona mais um termo. Ela minimiza a combinação dos erros quadráticos e os pesos, para então produzir uma rede generalizada e com respostas mais suaves, evitando assim o ajuste excessivo dos dados de forma automática (MACKAY, 1992), (FORESSE e HAGAN, 1997 *apud* GONÇALVES *et al*, 2010).

A função a ser minimizada neste caso é descrita pela equação (19):

$$F = (\lambda(SSE) + \delta(SSW)) \quad (19)$$

Onde λ e δ são os parâmetros ajustáveis no contexto do método Bayesiano de regularização, SSE é o somatório dos erros quadráticos e SSW o somatório dos pesos quadráticos. A solução e atualização dos dois parâmetros ajustados são realizadas aplicando a lei de Bayes.

2.5.8 TREINAMENTO COM GRADIENTE CONJUGADO E MOMENTO

O método do gradiente conjugado tenta escapar de mínimos locais de baixa qualidade utilizando outras direções de busca (direção conjugada ao gradiente). A idéia principal deste algoritmo surge de uma melhoria simples aplicada no método da retro-propagação. Ao invés de se utilizar um fator de aprendizagem (η) fixo, escolhe-se, a cada iteração, um novo fator através de uma busca linear que objetiva minimizar os valores do novo vetor de pesos sinápticos (WINANDY *et al*, 2007).

O momento permite que a rede considere em sua resposta não apenas o gradiente local, mas também a tendência na superfície de erro. Dessa forma, a rede minimiza o efeito dos mínimos locais. Os pesos sinápticos são alterados de acordo com a soma dos resíduos da última alteração realizada nos pesos.

Na retropropagação com momento, os pesos mudam na direção que é combinação do gradiente atual e do anterior. Esta é uma modificação no gradiente descendente cujas vantagens aumentam principalmente quando alguns dados de treinamento diferem da maioria (e possivelmente estão incorretos). Neste caso é desejável utilizar uma pequena taxa de aprendizado para evitar uma maior variação na direção de aprendizagem quando um par de padrões de treino não usual é apresentado. Entretanto, é também preferível manter o treinamento em um passo relativamente rápido quando os dados de treinamento forem bastante similares.

É possível obter convergência mais rapidamente se for adicionado um termo de momento for acrescentado às equações de atualização de pesos, sendo necessário para isso armazenar as atualizações de um ou mais padrões anteriores de treinamento.

Por exemplo, na forma mais simples de retropropagação com momento, os novos pesos para o passo de treinamento $t+1$ são baseados nos pesos dos passos t e $t-1$. As equações de atualização de pesos com o momento são:

$$w_{jk}(t+1) = w_{jk}(t) + \alpha \delta_k z_j + \mu [w_{jk}(t) - w_{jk}(t-1)] \quad (20)$$

ou

$$\Delta w_{jk}(t+1) = \alpha \delta_k z_j + \mu \Delta w_{jk}(t) \quad (21)$$

e

$$v_{ij}(t+1) = v_{ij}(t) + \alpha \delta_j x_i + \mu [v_{ij}(t) - v_{ij}(t-1)] \quad (22)$$

ou

$$\Delta v_{ij}(t+1) = \alpha \delta_j x_i + \mu \Delta v_{ij}(t) \quad (23)$$

Sendo w_{jk} o peso sináptico entre a camada oculta e a camada de saída, v_{ij} o peso sináptico entre a camada de entrada e camada oculta, α a taxa de aprendizagem e μ o momento, situado entre zero e um. O parâmetro δ_k é a parcela de erro de ajuste de correção de erro para w_{jk} e δ_j é a parcela de erro de ajuste de correção de erro para v_{ij} .

O momento permite que a rede faça certo ajuste nos pesos, tão grande forem as correções na mesma direção geral de vários padrões, enquanto que utilizando uma taxa de aprendizado menor previne uma resposta maior ao erro de qualquer padrão de treinamento. Também reduz a probabilidade de a rede encontrar pesos que são mínimos locais. Ao usar o momento, a rede caminha na direção combinada do gradiente atual com a direção anterior de correção de pesos.

2.5.9 PARADA ANTECIPADA DO TREINAMENTO

O treinamento da rede neural com retropropagação de erro busca alcançar um ponto de equilíbrio entre a memorização e a generalização, tornando-a apta a classificar corretamente tanto um padrão conhecido quanto um padrão novo de entrada

Desta forma, o processo de treinamento deve ser interrompido em determinado ponto, para isso podem ser adotadas estratégias como por exemplo fixar o número de épocas de treinamento ou estipular um valor para o erro quadrático total. Entretanto uma forma mais eficiente de encontrar o ponto de equilíbrio pode ser feito ao utilizar um conjunto de validação separado do conjunto de treinamento. Dessa forma, pode-se verificar o erro apresentado pela rede a determinados intervalos durante o processo de treinamento. Assim, enquanto o erro

para o conjunto de treinamento e validação diminuir, o treinamento continua. Quando o erro começa a aumentar, a rede passa a memorizar os parâmetros de treinamento de forma muito detalhada e perde a capacidade de generalização (fenômeno conhecido como *overfitting*), após um número de épocas estipulado em que o erro continua a crescer, o treinamento é interrompido e são restituídos os pesos e bias correspondentes ao mínimo erro de validação. (FAUSETT, 1994)

A técnica pode ser utilizada com todas as funções de treinamento apresentadas anteriormente, neste trabalho a mesma foi aplicada somente com o algoritmo de Levenberg-Marquardt.

3 TRABALHOS RELACIONADOS

O órgão de transportes norte americano FHWA – *Federal Highway Administration* – utiliza a classificação em 13 categorias mostrada na Tabela 1.

Tabela 1 - Classificação de veículos segundo o FHWA.

| | |
|----|---|
| 1 | Motocicleta |
| 2 | Carro de Passeio |
| 3 | Outros Veículos de 2 eixos e 4 pneus |
| 4 | Ônibus |
| 5 | Caminhões de dois eixos e 6 pneus |
| 6 | Caminhões de três eixos |
| 7 | Caminhões de quatro ou mais eixos |
| 8 | Carretas de até quatro eixos |
| 9 | Carretas de cinco eixos |
| 10 | Carretas de seis ou mais eixos |
| 11 | Carretas de mais de um reboque com até cinco eixos |
| 12 | Carretas de mais de um reboque com seis eixos |
| 13 | Carretas de mais de um reboque com sete eixos ou mais |

Existem vários estudos sobre classificação veicular usando tecnologias de detecção, incluindo sensores indutivos convencionais, sensores baseados em imagem, sensores acústicos, sensores magnéticos e sistemas de detecção por laço indutivo. A maior parte dos trabalhos descritos nesta seção utilizou como referência a classificação FHWA.

Estudos realizados por Lu *et al* (1992) Harlow e Peng (2001) e Gupte *et al* (2002) desenvolveram um modelo de classificação usando imagens em infravermelho capaz de distinguir quatro classes de veículos, incluindo três classes de veículos comerciais com taxa de 95%. O modelo de Harlow e Peng (2001) foi utilizado em um sistema de imagem na faixa de laser que identifica seis classes, incluindo três classes de veículos comerciais com taxa de 92%, enquanto Gupte *et al*

(2002) usou imagens de vídeo para distinguir entre carros e não-carros com 70% de acertos.

Nooralahiyan *et al* (1997) realizaram análises em assinaturas acústicas de veículos e desenvolveram um modelo capaz de distinguir entre quatro diferentes tipos de veículos, incluindo duas classes de veículos comerciais com 82,4% de acerto.

Um estudo mais recente de Cheung *et al* (2004) investigou a possibilidade de sensores magnéticos sem fio na classificação de veículos. O modelo obteve entre 63 e 75% de acertos para seis classes de veículos dependendo da configuração, mas com uma amostra de apenas 37 veículos.

Shin *et al* (2007) desenvolveram um modelo de classificação com base nas informações de eixos e peso dos veículos utilizando sensores *strain gauges*. Foram comparadas as abordagens utilizando Classificador Bayesiano Simples, Rede Neural com Retropropagação de Erro e Máquinas de Vetor Suporte (*Support Vector Machines* - SVMs), tendo sido verificado que o uso desta última técnica (SVM) apresentou os melhores resultados. O modelo distinguiu entre cinco categorias alcançando índice de classificação de 94,8% em conjunto de teste com 100 veículos em cada classe. Entretanto, esta tecnologia não detecta a presença contínua do veículo. Assim, podem ter ocorrido erros na separação de um veículo ao outro, tendo sido confundidos com um único veículo de maior comprimento ou até mesmo o contrário, especialmente sobre condições de tráfego instável.

Houve também um crescente interesse na classificação de veículos utilizando sistemas de assinatura magnética. Pursula e Pikkarainen (1994) usaram pioneiramente uma arquitetura de mapa auto-organizável para classificar veículos usando vetores de características obtidas dos perfis magnéticos coletados.

Posteriormente, Oh *et al* (2002) investigaram vários modelos e concluíram que a arquitetura da rede neural de retropropagação de erro (*backpropagation neural network*) foi superior a rede neural probabilística e mapas auto-organizáveis, utilizando características desenvolvidas em seus estudos como modelos de entrada. O modelo distinguiu entre sete categorias de veículos, incluindo quatro classes de veículos comerciais e obteve 82% de taxa de acerto.

O estudo feito por Sun *et al* (2003) revisou o uso de mapas auto-organizáveis. Foram utilizadas assinaturas magnéticas típicas de veículos para cada categoria definida como padrão para o mapa auto-organizável e o índice alcançado para classificação também foi de 82%, utilizando o mesmo esquema de classificação veicular de Oh *et al* (2002).

O sistema de classificação proposto por Ritchie *et al* (2005a) utilizou árvore de decisão heurística com base em quatro parâmetros extraídos do perfil magnético tendo sido obtidos índices de classificação de 85% e 89,3% respectivamente.

O sistema proposto por Calixto (2006) utilizou lógica nebulosa para classificar veículos em seis categorias, com taxa de acerto superior a 85% para todas as categorias. Em trabalho realizado por Oliveira *et al* (2010) foi proposto um sistema de classificação de veículos de acordo com o comprimento, utilizando rede neural, obtendo taxa de reconhecimento de 92,43% em um equipamento instalado em campo. No trabalho de Barbosa *et al* (2004) é descrito o desenvolvimento de um sistema inteligente para detecção contagem, medição de velocidade e identificação (classificação) de veículos. O projeto utilizou técnicas de processamento de sinais, como transformada rápida de Fourier (FFT). A FFT foi usada para análise e interpretação dos sinais gerados pelos laços de indução.

Ritchie *et al* (2005) utilizaram uma abordagem de árvore de decisão para classificar veículos em esquema muito próximo ao FHWA. Foram propostos três submodelos diferentes. Um total de 17 classes de veículos foram definidas para o primeiro modelo. Entretanto, devido a falta de dados de veículos para quatro das classes, o modelo resultante alcançou resultados de classificação para 13 classes, incluindo a distinção entre utilitários, vans e SUV em diferentes classes, obtendo índice de classificação correta de 81,53%, utilizando apenas um sensor indutivo. O segundo modelo combina *pickups*, vans e SUVs em uma única classe e obteve 85,43% de taxa de acertos, enquanto o terceiro modelo condensou veículos de passeio com *pickups*, vans e SUVs e alcançou 97,72% de acertos.

Oh C., Ritchie *et. al* (2007) propuseram sistema de classificação em quatro categorias a partir de rede neural probabilística (PNN), cuja implementação utilizou o esquema de decisão Bayesiano. As variáveis de entrada para classificação são as características extraídas dos perfis magnéticos dos veículos. A rede neural

apresenta duas camadas ocultas, função de ativação exponencial e tem como saída as probabilidades de pertinência a cada grupo para determinado veículo a ser classificado. Para treinamento o conjunto de dados foi dividido em subgrupos com quantitativos iguais de cada categoria a ser classificada. O menor índice de classificação encontrado foi de 70,8%, valor considerável bom tendo-se em vista as semelhanças entre os veículos pertencentes às quatro classes que apresentam características muito semelhantes entre os veículos (veículos de passeio, utilitários, vans, *sports utility*).

Um algoritmo de classificação baseado em rede neural com retropropagação de erro foi proposto por Ki e Baik (2006). Foram utilizados como entrada para a rede neural a taxa de variação da frequência do sinal que percorre o laço, o tempo de ocupação e a variação da frequência ao longo do tempo (perfil magnético), quando da passagem do veículo. O sistema classifica veículos em cinco categorias tendo obtido índices de acerto de até 91,3%. A rede neural apresenta topologia de três camadas com 11 neurônios na camada oculta, sendo escolhido pela média entre o número de variáveis de entrada e vetor de saída, sendo este a quantidade de classes de veículos

Jeng e Ritchie (2008) utilizaram um método heurístico que usa a combinação de árvore de decisão e técnicas de clusterização de média K para desenvolver um modelo de classificação utilizando dados de perfis magnéticos de sensores individuais. Três esquemas de classificação foram investigados, sendo que o esquema com mais classes tinha 15 classes incluindo treze classes comerciais e atingiu um índice de classificação de 93%. Entretanto o conjunto de dados continha muitos veículos de passeio e veículos utilitários leves, enquanto apenas três das classes remanescentes de veículos tinha uma quantidade de amostras de no mínimo 10 veículos no conjunto de dados.

Gadja e Sroka (2000) utilizaram agrupamento estatístico das características extraídas do perfil, com base na variação temporal para realizar a classificação de veículos em quatro categorias (Carro, carreta, ônibus urbano e ônibus articulado), obtendo taxa de acerto de 83%.

Em outro trabalho de Gadja, Sroka e Stencel (2001) é utilizado Algoritmo com base em método dos mínimos quadrados de informações relativas à amplitude

de variação do sinal normalizado do perfil magnético para classificação nas mesmas categorias de Gupte *et al* (2002) além de caminhão, tendo sido obtidos índices de classificação entre 71 a 95%.

Andreotti (2001) utilizou técnicas de clusterização e os parâmetros extraídos do perfil magnético variância, assimetria, desvio padrão, média e número de máximos nos perfis, para classificação em sete categorias, Foram utilizados 182 veículos para treinamento e 82 para testes, tendo sido atingido o índice de classificação de 97,5% para as categorias (Carro de Passeio, Carreta, Caminhão furgão, Camionete, Furgão, Ônibus e Moto).

Pursula e Kosonen (1989) apresentaram um sistema, baseado na plataforma PC, capaz de identificar até 10 categorias, analisando incidências estatísticas do perfil magnético. O índice de erros na classificação chegou a 31% para algumas categorias.

SUN (2000) apresentou dois métodos de classificação de veículos usando sete Classes (Carro de Passeio, Utilitário, Camionete, Limusine, Ônibus, Caminhão de dois eixos, Caminhão com mais de dois eixos). O índice de classificação total chegou a 87%. Foram utilizados parâmetros como transformadas do perfil, comprimento magnético do veículo, amplitude do sinal, área da curva gerada pelo perfil magnético, variância do perfil em relação a sua forma, primeira e segunda derivadas e pontos do perfil magnético.

Tok (2008) utilizou rede neural *feed forward* multi camada, com duas camadas ocultas treinada por algoritmo de Levenberg-Marquardt. O sistema utiliza os parâmetros do Comprimento e nove NOMAD (amplitude normalizada com interpolação), para classificação em 10 categorias. Os índices de classificação obtidos foram 91,6% para carros, 86,4% para veículos comerciais médios e 98,4% para veículos médios e grandes.

Heidemann et al (2004) utilizaram Árvore de decisão e os parâmetros comprimento da plataforma e número de eixos para classificação nas categorias (utilitários, passageiro, caminhões), obtendo os respectivos índices de classificação 34,43%, 76,4 , 75,75% e total de 63%.

Na Tabela 2 é apresentado o resumo dos diversos trabalhos de classificação de veículos através de sensores indutivos, sendo apresentados os autores, o ano, o

tamanho da base de dados (treino e teste), o número de classes, o percentual de acerto e a técnica utilizada.

Tabela 2 - Comparação entre trabalhos sobre classificação através de sensores indutivos

| Autor | Técnica Adotada | Variáveis de entrada | Número de Classes | Acerto (%) | Total Veículos |
|------------------------------|---|---|---|----------------|----------------|
| Pursula e Pikkarainen (1994) | mapa auto-organizável (Rede Neural Mapa de Kohonem) | Perfil magnético | 7 | 80 | 737 |
| Oh <i>et al</i> (2002) | rede neural de retropropagação de erro (<i>backpropagation neural network</i>) superior a rede neural probabilística e mapas auto-organizados | Máxima amplitude, comprimento magnético, parâmetro de forma e área sob a curva do perfil | 7, incluindo 4 classes de veículos comerciais | 83 | 788 |
| Sun <i>et al</i> (2003) | Heurística e mapas auto-organizáveis – 13 neurônios | Heurística: magnitude, comprimento, <i>skewness</i> curtose SOFM: 93 ESI do perfil | | 82 | 2137 |
| Ritchie <i>et al</i> (2005) | árvore de decisão para classificar veículos em esquema muito próximo ao FHWA | Comprimento, máxima amplitude, DOS, SP | 1º modelo: 13 classes (distinção entre utilitários, vans e SUV): 2º modelo (<i>pickups</i> , vans e SUVs em uma única classe : 3º modelo (veículos de passeio com pickups, vans e SUVs): | 90 99 92 | 9161 |
| Calixto (2006) | Lógica Fuzzy | Comprimento magnético, valor médio, número de inversões, valor médio das inversões, variância normalizada | 6 | 97 | 9313 |

| | | | | | |
|---|--|---|--|---------|------|
| Continuação Oh C., Ritchie, S.G., (2007) | rede neural probabilística (PNN) com esquema de decisão Bayesiano | Comprimento, amplitude, desvio padrão, SP e DOS | 4 (veículos de passeio, utilitários, VANs, sports utility) | 71 | 240 |
| Ki e Baik (2006) | rede neural com retropropagação de erro; 19 entradas, 5 saídas, 11 neurônios camada oculta | Taxa de variação de frequência (10 pontos e 9 pontos amostrados do perfil magnético) | 5 | 91 | 1055 |
| Jeng and Ritchie (2008) | método heurístico que usa a combinação de árvore de decisão e técnicas de clusterização de média K | Máxima amplitude, parâmetro de forma, grau de simetria, comprimento magnético, média, desvio padrão, curtose, mediana | 3 esquemas de classificação - esquema com mais classes tinha 15 classes incluindo treze classes comerciais | 93 | 7932 |
| Gadja e Sroka (2000) | | Características do perfil, com base na variação temporal | 4 categorias | 83 | |
| Gadja Sroka e Stencel (2001) | Algoritmo com base em método dos mínimos quadrados | Informações relativas à amplitude de variação do sinal normalizado | 5 | 71 a 95 | |
| Andreotti (2001) | Técnicas de clusterização | variância, assimetria, desvio padrão, média e número de máximos nos perfis | 7 | 98 | 248 |
| Pursula e Kosonen (1989) | | Incidências estatísticas do perfil magnético | 10 | 69 | |
| Sun (2000) | Árvore de decisão heurística | transformadas do perfil, comprimento magnético do veículo, amplitude do sinal, área da | 7 | 87 | 300 |
| Continuação | | | | | |

| | | | | | |
|-------------------------------|---|---|--|----|-----|
| | SOFM | curva gerada pelo perfil magnético, variância do perfil em relação a sua forma, 1ª e 2ª derivadas. Pontos do perfil | 9 e 7 | 71 | |
| Tok (2008) | Multi Layer FF, 2 camadas ocultas, Treinamento LM | Comprimento, 9 NOMAD (amplitude normalizada com interpolação) | 10 | 98 | 800 |
| Heidemann <i>et al</i> (2004) | Árvore de decisão | Comprimento da plataforma e número de eixos | 3 classes (utilitários, passageiro, caminhões) | 63 | 366 |

É possível verificar que os diversos estudos sobre classificação de veículos apresentam um número menor na base de dados para veículos do tipo caminhão, carreta e ônibus em relação a veículos de passeio ou utilitários. Isto ocorre pelo fato de a maioria das pesquisas terem sido feitas em áreas urbanas, onde predomina o tráfego de veículos menores. Outro aspecto observado é que na maioria dos trabalhos a base de dados não apresenta uma quantidade homogênea de veículos em cada categoria. Assim, o presente trabalho buscou superar esta limitação e foi obtida uma base de dados com representação significativa de veículos comerciais tais como ônibus, caminhões e carretas e com quantidades homogêneas entre as diferentes categorias a serem classificadas.

Os métodos de classificação utilizados pelos diferentes trabalhos revisados contemplaram o uso de heurísticas, técnicas de inteligência artificial (redes neurais e lógica *Fuzzy*), técnicas de clusterização e algoritmos de distância mínima.

4 MÉTODO

Para garantir uma grande quantidade de perfis magnéticos, a fim de agregar dados suficientes, permitindo uma boa análise estatística, o processo de coleta foi automatizado em conjunto com a imagem do veículo correspondente. A captura pelas câmeras dos equipamentos foi regulada para garantir a visualização completa do veículo, permitindo a compreensão correta da categoria equivalente. Os dados foram coletados a partir de um equipamento do tipo DEV (Detector Eletrônico de Velocidade), fabricante Perkons S/A, localizado na BR-376, próximo a represa da Voçoroca. De forma a obter uma quantidade homogênea de veículos das diferentes classes e agregar possíveis veículos ao banco de dados que não circulam neste equipamento, foram coletadas amostras de ônibus, vans e motos em outros equipamentos, com mesmo modelo de sistema de detecção, instalados em Curitiba e Campo Grande.

A separação dos tipos de veículos nas diferentes categorias, com base na imagem analisada, levou em consideração algumas premissas para tratar *outliers*, ou seja, veículos que trafegam sobre o equipamento e geram no sistema de detecção uma condição anormal. As tratativas para as diversas categorias foram:

- Motos: Foram geradas imagens de veículos formados pela composição de duas ou mais motos passando simultaneamente sobre o mesmo laço indutivo, cujo perfil magnético não é reconhecido pelo sistema como válido. O perfil gerado se assemelha mais a um veículo de passeio, portanto seria muito difícil caracterizar tal tipo de situação de múltiplas motos passando pelo sensor e assim, tais imagens de veículos foram descartadas e não fizeram parte da base de dados.

Outro problema são motos que trafegam muito próximas as bordas dos sensores indutivos, sendo esta a região de menor sensibilidade, o que acaba gerando um perfil magnético de amplitude muito baixa e diferente daquele que seria produzido caso o mesmo veículo trafegasse pelo centro do sensor.

- Veículos de passeio, camionetes e caminhonetes: muitos ao trafegarem entre duas faixas de rolamento (entre pista) acabam produzindo um perfil magnético de amplitude menor, mais próximo à categoria moto. Tais casos também foram descartados da base de dados.

- Microônibus: Embora apresentem características físicas (plataforma e chassi) mais próximas às vans do que aos ônibus, foram mantidos nesta última categoria, pelo fato de ambos (ônibus e microônibus) pertencerem ao grupo de veículos de passageiros de acordo com a subclassificação quanto à espécie do CTB, tratada em seu artigo 96
- Caminhonetes (pickups) e vans: Foram mantidas nesta classe mesmo aquelas mistas (cabine de caminhonete com carroceria de caminhão, em madeira) por serem consideradas como veículos mistos, de acordo com a subclassificação quanto à espécie do CTB. Alguns veículos do tipo Kombi adaptados, em forma de pickup, foram deixadas na categoria caminhonete.
- Veículos puxando carretinha: foram descartados, pois o perfil magnético se assemelha a outras classes.

O banco de dados gerado foi distribuído em classes, conforme análise da imagem gerada para cada veículo atribuiu-se uma classe equivalente. A base de dados foi constituída por 3824 veículos, sendo 591 carros, 474 motos, 518 ônibus, 640 caminhões, 516 carretas, 328 vans, 436 caminhonetes e 321 camionetas.

Foram extraídas 11 características dos perfis magnéticos normalizados, para serem utilizadas como entrada para o sistema de classificação. As características foram escolhidas de forma a tornar as classes facilmente diferenciáveis e foram tomadas com base na literatura revisada (CALIXTO, 2006), (OH *et al*, 2002), (PURSULA e KOSONEN, 1989), (OH *et al*, 2007) e (RITCHIE *et al*, 2005). É apresentada a seguir a distribuição estatística para o parâmetro comprimento magnético, as demais características extraídas para a base de dados de veículos são mostradas no Anexo I.

4.1 COMPRIMENTO MAGNÉTICO

A variação do comprimento magnético pode ser observada estatisticamente para as categorias, conforme mostrado no histograma da Figura 12. O gráfico mostra a distribuição estatística do banco de dados de veículos considerando este parâmetro específico.

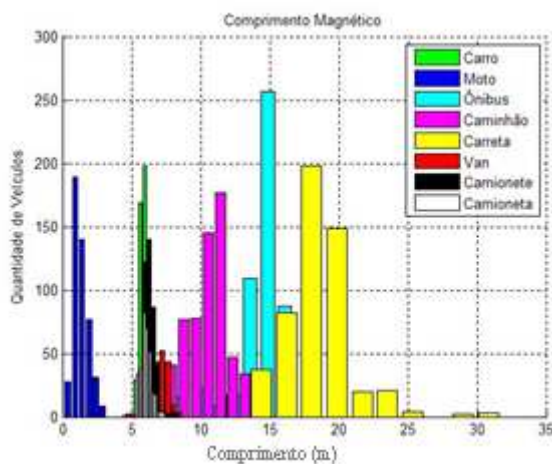


Figura 12 - Distribuição do comprimento magnético dos veículos entre as oito categorias.

O parâmetro comprimento magnético permite a diferenciação das categorias moto, caminhão e carreta. Porém, a diferenciação de camionetas, vans e utilitários torna-se impossibilitada e as categorias apresentam sobreposição em relação ao grupo de caminhões. Existe também uma pequena superposição entre os grupos de veículos de carretas e ônibus.

4.2 MÚLTIPLOS PERFIS

De forma que os perfis magnéticos característicos das oito categorias possam ser analisados simultaneamente, os mesmos foram traçados juntos no gráfico da Figura 13.




Figura 13 - Perfis característicos das diferentes categorias.

Com base no gráfico, é possível verificar que podem ser definidos diferentes patamares para a amplitude máxima, conforme as diversas classes. Os carros estão bem destacados de um segundo grupo contendo ônibus, vans e camionetas, sendo seguidos pelo grupo de carretas e caminhões e na escala mais baixa o grupo das motos.

As inflexões (picos) nas curvas características dos perfis, também permitem identificar as categorias, sendo que caminhões carretas e ônibus estariam em um patamar diferenciado de veículos com menor número de picos, como carros, motos e utilitários (vans, caminhonetes e camionetas).

Estes três parâmetros: amplitude máxima, comprimento magnético e número de inversões, foram levantados para cada um dos perfis amostrados. A distribuição dos mesmos em um espaço tridimensional (amplitude máxima, comprimento magnético e número de inversões) é mostrada na Figura 14.




Figura 14 - Distribuição das amostras em um espaço tridimensional (Número de Pontos X Valor Médio X Número de Máximos e Mínimos)

A Figura 14 mostra as diversas categorias posicionadas em regiões distintas do espaço, separáveis sem muitas dificuldades, com exceção para as classes de utilitários (vans, caminhonetes e camionetas), como já era esperado e comentado anteriormente. Essa figura mostra também que as características escolhidas devem resolver muito bem o problema da classificação, além de reduzir significativamente a complexidade do problema.

4.2.1 REDE NEURAL: TREINAMENTO, FLUXOGRAMAS, ARQUITETURA DA REDE NEURAL E TREINAMENTO

Para implementar o sistema de classificação veicular, foi utilizado rede neural perceptron multicamada (MLP). A função de ativação tangente hiperbólica (tanh) foi escolhida para os neurônios da camada oculta. As entradas utilizadas para a rede neural foram constituídas pelas características extraídas do perfil de cada veículo, descritos na seção 2.3. A saída é constituída por oito neurônios, sendo um para cada classe de veículos a categorizar. A Figura 15 mostra a topologia do tipo de rede utilizada.




Figura 15 - Estrutura da rede MLP (*Multi-layer Perceptron*) sendo x o vetor de entradas e y o vetor das saídas.

O treinamento e simulação foram feitos no MATLAB 7 utilizando o *Neural Network ToolBox*. Três tipos de algoritmos de treinamento foram testados: Levenberg-Marquardt, Regularização Bayesiana (trainbr) e Gradiente Conjugado com Momento (traingdm) sendo o critério de parada o número máximo de 300 épocas de treinamento ou o erro quadrático médio inferior a 1×10^{-10} . O treinamento com o algoritmo de Levenberg-Marquardt também foi utilizado como critério de parada, a interrupção antecipada do treinamento.

Foram testadas diversas configurações de rede, sempre com uma camada oculta, variando-se o número de neurônios da camada de entrada para cada teste. O número de neurônios da camada oculta variou de acordo com os parâmetros de entrada, tendo sido utilizado sempre o valor inteiro mais próximo da média entre o número de entradas e saídas (KI e BAIK, 2006).

O total de veículos foi dividido em três conjuntos (35% para treinamento, 15% para validação e 50% para teste) mantendo-se a proporção para o total de veículos de cada classe. As entradas de dados para treinamento e validação estavam agrupadas por classes em um arquivo contendo todos os padrões da classe 1 seguidos pelos padrões da classe 2 e assim sucessivamente. Como os algoritmos utilizados pelo MATLAB atualizam os parâmetros após a apresentação de cada padrão, não é recomendada a apresentação de padrões de uma mesma classe. Por isso, o conjunto de treinamento teve de ser "embaralhado".

O treinamento tradicional de redes neurais via retropropagação de erro (*backpropagation*) parte de uma solução inicial e através da descida do gradiente da

função de erro busca a minimização desta função. Visto que tal função é repleta de mínimos locais, diferentes inicializações do vetor de pesos podem conduzir a diferentes soluções (diferentes mínimos locais).

Desse modo, o treinamento e validação da rede foram repetidos 10 vezes, sendo armazenados os índices de classificação obtidos de forma a ser escolhido o modelo gerado a partir de cada treinamento com o maior número de acertos de classificação para o conjunto de validação. Os conjuntos de treinamento, validação e teste foram mantidos fixos, alterando-se somente o ponto inicial do algoritmo de retropropagação.

Uma vez escolhida a topologia da rede, com melhores resultados na classificação, a rede é novamente treinada utilizando todo o conjunto de dados de treinamento mais validação, antes de ser efetivamente testada. O conjunto de teste simula uma situação real em que padrões desconhecidos são apresentados à rede, verificando sua capacidade de generalização por classificar corretamente um determinado veículo com base no aprendizado adquirido com o primeiro conjunto de dados.

O algoritmo em Matlab para executar os procedimentos envolvidos na classificação é descrito na sequência.

- 0) A base de dados possui os parâmetros extraídos do perfil magnético dos veículos coletados, apresentando como saída a classe veicular correspondente, classificada de forma manual através da análise das imagens dos veículos.
- 1) Carregamento dos dados do arquivo de entrada de treinamento para a memória do Matlab.
- 2) É armazenado o tamanho (linhas colunas) do banco de dados de entrada para treinamento.
- 3) É feita a separação da matriz de dados em matriz de entrada e matriz com as classes correspondentes.
- 4) Visando evitar problemas de estagnação do treinamento de MLPs (região de saturação das funções de ativação sigmoidais), as entradas e saídas devem ser normalizadas em uma dada faixa, comumente feita igual a $[0 \ 1]$. As características que definem o padrão de entrada podem ser oriundas de diversas medidas. Sendo assim, a normalização dos sinais deve ser feita para cada característica

- 5) Para um dado padrão de entrada que reflete as características extraídas do perfil magnético de determinado veículo, o modelo neural deve fornecer a categoria veicular correspondente entre as 8 possibilidades consideradas numeradas de 01 a 08
- 6) Para este problema de classificação multi-classe devem ser definidas superfícies de decisão para separação de diversas categorias. Neste caso é aplicada uma representação 1 de n. , ou seja, para n ocorrências, tem-se n variáveis, se o padrão pertence a i-ésima classe, a i-ésima variável é feita igual a 1 e as demais iguais a zero.
- 7) Como os neurônios de saída da rede são do tipo tangente hiperbólica, ou seja, limitados entre $[-1 \ 1]$, a codificação 1 de n na forma $[0,1]$ não é a mais indicada, sendo substituídos os sinais iguais a 0 por -1.
- 8) Codificados os sinais de entrada e de saída, é iniciado o treinamento do modelo. A avaliação da MLP é feita através do erro para um conjunto de validação. Desta forma, é necessária a separação do conjunto de dados em dois conjuntos, um de treinamento e outro de teste. Do conjunto de dados, foram dedicados $\frac{3}{4}$ dos dados para treinamento e $\frac{1}{4}$ para validação, sendo replicada a mesma proporção para as classes de veículos.
- 9) Como o conjunto de treinamento e validação foi separado por classe, primeiramente todos os padrões da classe 1 serão apresentados, posteriormente os da classe 2 e assim sucessivamente. Como os algoritmos utilizados pelo MATLAB atualizam os parâmetros após a apresentação de cada padrão, não é recomendada a apresentação de padrões de uma mesma classe. Para isso, o conjunto de treinamento teve de ser "embaralhado".
- 10) Definidos os conjuntos de treinamento e validação, pode ser iniciado o treinamento do modelo. O erro para o conjunto de validação será utilizado para parada antecipada do treinamento e seleção do número de neurônios na camada oculta. Segundo o teorema da aproximação universal, uma camada oculta é suficiente, sendo necessária a definição do número de neurônios nessa camada. Para isso, adotado o critério do número médio de neurônios entre o total de parâmetros de entrada e número de saídas. Foram utilizadas as funções padrão da toolbox de Redes Neurais do Matlab. Antes do algoritmo de treinamento é necessária a definição do modelo, sendo especificados os limites de variação das variáveis de entrada (de -1 a 1), o limite de variação para a estrutura.
- 11) O treinamento da rede é repetido 10 vezes de forma a se verificar o conjunto de vetores de pesos iniciais da rede neural que alcança o maior índice de classificação para o conjunto de validação.
- 12) O número de neurônios na camada de entrada (camada sensorial) é igual ao número de parâmetros extraídos do perfil magnético. O número de

neurônios da camada de saída é igual ao número de categorias de veículos objeto da classificação.

13) Comumente, os neurônios da camada oculta são do tipo sigmoidal, ou tangente hiperbólica (tanh). Em problemas de classificação, a camada de saída também apresenta neurônios deste tipo. Esta informação é encapsulada em uma variável do tipo célula, com tantas células quanto camadas ocultas + 1.

14) É então definido o grafo que especifica a rede neural desejada pelo usuário, sendo sorteados os valores iniciais dos pesos sinápticos e dos bias do modelo.

15) A Rede definida está apta para ser treinada. Antes porem são escolhidos alguns parâmetros relacionados com o algoritmo de treinamento, como por exemplo, o algoritmo de treinamento a ser utilizado, o número de épocas de treinamento, o critério de parada.

16) É feito o treinamento para cada modelo, utilizando a estratégia relacionada (minimização do erro para o conjunto de treinamento, parada antecipada do treinamento, treinamento bayesiano e gradiente conjugado com momento)

17) É avaliado cada modelo para o conjunto de treinamento

18) É avaliado cada modelo para o conjunto de validação.

19) Para cada modelo, é escolhida a melhor estrutura, com base no erro para o conjunto de validação

20) A escolha da melhor estrutura (pesos sinápticos e bias) é treinada utilizando todo o conjunto de treinamento e validação, com exceção da parada antecipada, pois não existe um conjunto de validação para encerrar o algoritmo.

21) É feito o carregamento dos dados referentes ao conjunto de teste. Este conjunto é utilizado para simular a operação real do modelo treinado. Este arquivo apresenta estrutura semelhante ao arquivo de treinamento, ou seja, cada linha representa um padrão, com a ultima coluna representando a saída desejada.

22) As entradas e saídas do conjunto de teste são normalizadas e codificadas.

23) É feita a avaliação dos modelos treinados para o conjunto de teste.

O treinamento e simulação de todas as redes deste trabalho foram feitas no MATLAB 7 (BEALE *et al*, 2011) utilizando a *Neural Network Toolbox*. Foram testados os seguintes algoritmos de treinamento disponível na *toolbox* (Levenberg

Marquardt, Regularização Bayesiana e Gradiente Conjugado com Momento). O algoritmo de Levenberg Marquardt foi também testado utilizando o critério de parada antecipada (Early Stopping).

4.2.2 TREINAMENTO COM LEVENBERG MARQUARDT

O primeiro algoritmo de treinamento testado foi o de Levenberg Marquardt.

O teste do algoritmo foi feito com os mesmos conjuntos já descritos anteriormente. O número máximo de épocas de treinamento foi estabelecido em 300 e a magnitude mínima do gradiente foi estabelecida em 1×10^{-11} .

4.2.3 TREINAMENTO COM PARADA ANTECIPADA

O treinamento pelo método de Levenberg-Marquardt foi também realizado adotando-se o critério de parada antecipada para interromper o treinamento.

Os testes foram realizados utilizando os mesmos conjuntos já descritos anteriormente para treinamento e validação. O algoritmo foi interrompido quando a tolerância manteve-se maior que o valor esperado durante cinco épocas de treinamento, de forma a evitar que um ponto de mínimo na curva de erro do treinamento viesse a interromper o algoritmo antes do momento correto.

4.2.4 TREINAMENTO COM REGULARIZAÇÃO BAYESIANA

O algoritmo de regularização Bayesiana (função `trainbr` do Matlab), foi testado para o sistema de classificação proposto neste trabalho.

De forma a ser feita comparação com outros algoritmos de treinamento, o número máximo de épocas de treinamento foi mantido em 300 e a magnitude mínima do gradiente em 1×10^{-11} .

4.2.5 TREINAMENTO COM GRADIENTE CONJUGADO E MOMENTO

O algoritmo de gradiente conjugado e momento (função `traingdm` do Matlab), foi testado para o sistema de classificação proposto neste trabalho.

De forma a ser feita comparação com outros algoritmos de treinamento, o número máximo de épocas de treinamento foi mantido em 300 e a magnitude mínima do gradiente em 1×10^{-11} .

Na Tabela 3 são apresentados os resultados dos testes com o conjunto de validação, para os diferentes algoritmos de treinamento considerados, tendo sido repetido o número de simulações variando os pesos e bias iniciais para o modelo. Os ensaios foram feitos com rede MLP com 11 parâmetros de entrada, 08 parâmetros de saída e 10 neurônios na camada oculta. Foram deixados em vermelho o pior índice de classificação obtido e em azul o melhor.

Tabela 3 - Percentuais de acertos na classificação para conjunto de validação dos diferentes algoritmos testados.

| Algoritmo/Iteração | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | menor | maior | média | desvio padrão |
|---|------|------|------|------|------|------|------|------|------|------|-------|-------|-------|---------------|
| Levenberg-Marquardt | 83,9 | 90,7 | 80,5 | 87,5 | 89,0 | 87,1 | 76,5 | 88,4 | 77,3 | 81,4 | 76,5 | 90,7 | 84,2 | 5,1 |
| Levenberg-Marquardt com Parada Antecipada | 86,4 | 89,0 | 70,8 | 89,4 | 89,8 | 89,0 | 69,1 | 75,2 | 51,5 | 78,8 | 51,5 | 89,8 | 78,9 | 12,6 |
| Regularização Bayesiana | 87,3 | 89 | 89 | 87,7 | 87,3 | 87,5 | 88,4 | 87,5 | 87,1 | 89,0 | 87,1 | 89,0 | 88,0 | 0,8 |
| Gradiente Conjugado com Momento | 29,7 | 8,3 | 8,3 | 17,2 | 27,5 | 15,5 | 17,2 | 8,3 | 14,4 | 11,4 | 8,3 | 29,7 | 15,8 | 7,6 |

É possível verificar que o modelo utilizando o algoritmo de Levenberg-Marquardt apresenta a maior taxa de classificação, porém o menor valor apresentado é de 76,5 %. O desvio padrão do modelo utilizando algoritmo de parada antecipada é ainda maior, sendo a menor taxa de classificação obtida de 51,5%. O algoritmo de gradiente conjugado com momento não apresentou resultados satisfatórios, tendo sido o maior índice obtido de apenas 29,7%.

De todos os algoritmos testados, o que apresentou menor variação de resultados e melhor taxa de acertos de classificação, foi o de Regularização Bayesiana (*Bayes Regulation*) que foi adotado até o final do trabalho. O algoritmo sofre pouca influência dos pesos sinápticos iniciais para o treinamento de cada modelo.

4.3 REDES NEURAIS EM TOPOLOGIA 1 DE N

De forma a verificar se o mapeamento entre as variáveis de entrada os neurônios de saída está adequado, outra topologia de rede neural foi proposta. A

topologia consiste em oito redes neurais binárias, cada uma produzindo uma saída entre -1 e 1 indicando o grau de pertencimento de um conjunto de características de entrada a uma determinada classe, a qual a rede busca identificar. Assim, quanto mais a saída produzida se aproximar de um, mais provavelmente o vetor de entrada pertence a categoria identificada por aquela rede neural, e quanto mais próximo de -1 menores as chances de pertencer a esta classe. Foi utilizada a rede neural perceptron multicamada com retropropagação de erro e algoritmo de treinamento de regularização bayesiana, para fins de comparação com o caso utilizando uma única rede.

O treinamento e a validação são feitos para cada uma das 08 MLPs utilizadas, de forma similar para o caso de uma única rede. Para os testes cada padrão de entrada é apresentado a cada uma das oito redes e o veículo é classificado verificando-se o maior índice produzido entre as oito MLPs. Foram feitos testes utilizando 6 e posteriormente 10 neurônios na camada oculta de cada rede neural. O número de seis neurônios foi escolhido por ser o valor médio entre o número de entradas (11 neurônios) e a saída (um neurônios). O valor de 10 neurônios foi utilizado a fim de realizar a comparação de resultados com a rede MLP única, utilizada para categorização.

4.4 DISTÂNCIA EUCLIDIANA

De forma a verificar o sistema de classificação utilizando rede neural, foram realizados testes com sistemas de classificação baseados em métodos lineares, como o classificador por distância mínima.

Neste sistema, a classificação dos veículos é feita pela comparação entre o vetor de características extraídas do perfil magnético do veículo a ser classificado com um conjunto de vetores de características pré-classificados, correspondente a média dos parâmetros de cada categoria de veículos. A classificação de um dado vetor de característica é dada pela proximidade deste a algum dos vetores do banco de dados. Esta proximidade é obtida pela distância euclidiana entre os vetores.

Cada característica extraída do perfil é uma coordenada de um sistema de coordenadas n-dimensional. Quanto menor a distância entre o vetor analisado e um dos vetores do banco de dados, mais parecidos são os perfis e mais provável é que este pertença à mesma classe do perfil do banco de dados.

A comparação também pode ser feita entre o vetor contendo os pontos do perfil magnético de determinado veículo a ser classificado e os perfis magnéticos médios para cada categoria, calculados a partir do mesmo conjunto de dados para treinamento. Para que a distância seja calculada, os vetores devem ser ajustados para conterem o mesmo número de pontos, isto é feito acrescentando-se zeros ao final do vetor com menor dimensão.

4.5 DISTÂNCIA EUCLIDIANA NORMALIZADA

Conforme já mencionado, algumas características descrevem uma classe melhor do que outras como é o caso, por exemplo, do comprimento magnético, capaz de separar facilmente as carretas dos demais tipos de veículos. Entretanto, no cálculo da distância euclidiana a característica com maior escala acaba predominando sobre as demais.

A medida de similaridade que permite fazer isto é a distância Euclidiana normalizada, assim as escalas de cada dimensão ficam normalizadas pelo valor correspondente do centróide.

4.6 DISTÂNCIA DE MAHALANOBIS

A distância de Mahalanobis é implementada no Matlab através da função mahal. Entretanto, as matrizes de covariância para os parâmetros das caminhonetes e camionetas, por apresentarem valores muito baixos acabam gerando uma função inversa com valores infinitos. Assim, a equação (8) (seção 2.4.3) foi implementada no Matlab, utilizando a função pinv, que calcula a matriz pseudo-inversa levando em conta o desvio padrão de seus valores. Caso o cálculo gere valores menores que certa tolerância calculada, os mesmos são tratados como zero.

$$D(x, m_j) = (x - m_j) \sigma_j^{-1} (x - m_j)^T \quad (24)$$

5 RESULTADOS

5.1 CLASSIFICAÇÃO EM SEIS CATEGORIAS

O primeiro sistema proposto classifica veículos em seis categorias: carro, moto, ônibus, caminhão, carreta e utilitários (caminhonetes, camionetas e vans). Foram feitos testes utilizando o método não-linear (Rede Neural) e o método linear (distância de Mahalanobis). Para o sistema implementado através de rede neural, foram utilizados três parâmetros de entrada (item 5.1.1) e 11 parâmetros de entrada (item 5.1.2). Já a distância de Mahalanobis foi calculada utilizando-se três parâmetros de entrada (item 5.1.3). Os métodos lineares da distância euclidiana e distância euclidiana normalizada também foram testados, entretanto apresentaram resultados na classificação inferiores a distância de Mahalanobis, sendo apresentados somente os resultados totais na Tabela 23.

5.1.1 SEIS CATEGORIAS – REDE NEURAL – TRÊS PARÂMETROS – COMPRIMENTO MAGNÉTICO, MÁXIMA AMPLITUDE E NÚMERO DE PICOS

A Tabela 4 apresenta os resultados na matriz de confusão. As simulações do sistema classificador foram feitas com a base de parâmetros dos 1918 veículos. Nas linhas está registrada a quantidade de veículos referente à categoria de acordo com a imagem observada e nas colunas está registrada a classificação que o sistema atribuiu. Assim observando a linha cujo primeiro item é Carreta, por exemplo, verifica-se que quatro carretas foram classificadas como ônibus, duas carretas foram classificadas como caminhão, 252 foram classificadas corretamente e nenhuma foi classificada como carro, moto, ou utilitário. Ao verificar a tabela pela vertical, tomando-se a coluna “Carreta” pode-se ler que nenhum carro, moto e utilitário foram classificados como carreta e um ônibus e quatro caminhões o foram

A Tabela 5 apresenta os índices utilizados para medição do desempenho do sistema: taxa de acerto e taxa de falsos negativos. A taxa de acerto é a quantidade total de veículos classificados corretamente em relação ao total de veículos daquela categoria. Os falsos negativos são constituídos pelos veículos que não deveriam ter sido classificados em determinada categoria mais o foram. A taxa é medida

considerando esta quantidade de falsos negativos em relação ao total de veículos de todas as categorias.

Por exemplo, das 258 carretas 252 foram classificadas corretamente, o que representa uma taxa de acerto de 97,67% para esta categoria. Na mesma tabela a taxa de falsos negativos para a categoria Carreta é de cinco veículos em 1918, que resulta em 0,26%. Na mesma tabela a taxa de falsos negativos para a categoria Ônibus é de oito veículos em 1918, que resulta em 0,42%.

A utilização de apenas três parâmetros, considerados mais significativos para separação entre classe (conforme seção 4.2), possibilitou que o sistema atingisse índice geral de classificação de quase 97%. Conforme a Tabela 5, todas as categorias apresentaram índices superiores a 95% e a taxa de falsos negativos não foi superior a 2% para nenhuma categoria.

Tabela 4 - Matriz de confusão em seis categorias utilizando Rede Neural e três parâmetros característicos do perfil magnético.

| CATEGORIA REAL | CLASSIFICAÇÃO REDE NEURAL | | | | | | Total Real |
|------------------------|---------------------------|------|--------|----------|---------|-------------|---------------|
| | Carro | Moto | Ônibus | Caminhão | Carreta | Utilitários | |
| Carro | 283 | 1 | 0 | 0 | 0 | 12 | 296 |
| Moto | 0 | 239 | 0 | 0 | 0 | 0 | 239 |
| Ônibus | 0 | 1 | 248 | 3 | 1 | 6 | 259 |
| Caminhão | 0 | 0 | 0 | 305 | 4 | 12 | 321 |
| Carreta | 0 | 0 | 4 | 2 | 252 | 0 | 258 |
| Utilitários | 7 | 1 | 4 | 1 | 0 | 532 | 545 |
| Total Classificação | 290 | 242 | 256 | 311 | 257 | 562 | 1918 |

Tabela 5 - Percentuais de Classificação para o conjunto de testes, utilizando Rede Neural com três parâmetros de entrada.

| | Carro | Moto | Ônibus | Caminhão | Carreta | Utilitários | Total |
|---------------------------|-------|--------|--------|----------|---------|-------------|-------|
| Taxa de acerto (%) | 95,61 | 100,00 | 95,75 | 95,02 | 97,67 | 97,61 | 96,92 |
| Taxa Falsos Negativos (%) | 0,36 | 0,16 | 0,42 | 0,31 | 0,26 | 1,56 | 3,08 |

No trabalho desenvolvido por Calixto (2006) foi implementado um sistema baseado em Lógica *Fuzzy* para classificar veículos nas mesmas seis categorias, tendo sido utilizados além dos três parâmetros, o valor médio de picos e a variância normalizada. É possível verificar na Tabela 6 que os resultados de classificação

apresentaram a mesma ordem de grandeza para o índice de classificação geral. Os testes realizados por Calixto foram feitos com um total de 9327 veículos sendo 6092 carros, ou seja, não foi utilizado um conjunto balanceado com quantidades proporcionais de veículos em cada classe.

Tabela 6 - Percentuais de Classificação para o conjunto de testes, utilizando Sistema *Fuzzy* com cinco parâmetros (CALIXTO, 2006).

| | Carro | Moto | Ônibus | Caminhão | Carreta | Utilitários | Total |
|----------------------------------|-------|-------|--------|----------|---------|-------------|-------|
| Taxa de acerto (%) | 98,62 | 99,57 | 96,71 | 94,39 | 98,42 | 91,16 | 97,44 |
| Taxa Falsos Negativos (%) | 0,53 | 0,02 | 0,23 | 0,37 | 0,04 | 1,23 | 2,41 |

5.1.2 SEIS CATEGORIAS – REDE NEURAL – 11 PARÂMETROS

A Tabela 7 apresenta a matriz de confusão para classificação de seis categorias de veículos, utilizando 11 parâmetros como entrada para a rede neural. Comparando-se os resultados da Tabela 8 com os obtidos pela Rede Neural com apenas três parâmetros como neurônios de entrada, é possível verificar que o aumento de parâmetros de três para 11 não acarreta ganho significativo no desempenho do sistema, elevando o resultado de classificação geral em apenas 1% e reduzindo o índice de falsos negativos na mesma proporção. O maior número de parâmetros permitiu principalmente que menos carros fossem classificados como utilitários e menos utilitários fossem classificados como ônibus, o que é justificado pela similaridade entre as classes apresentadas.

Tabela 7 - Matriz de confusão em oito categorias utilizando Rede Neural e 11 parâmetros característicos do perfil magnético para classificação em seis categorias.

| CATEGORIA REAL | CLASSIFICAÇÃO REDE NEURAL | | | | | | Total Real |
|----------------------------|---------------------------|------|--------|----------|---------|-------------|------------|
| | Carro | Moto | Ônibus | Caminhão | Carreta | Utilitários | |
| Carro | 292 | 0 | 0 | 1 | 0 | 3 | 296 |
| Moto | 0 | 239 | 0 | 0 | 0 | 0 | 239 |
| Ônibus | 0 | 0 | 253 | 1 | 1 | 4 | 259 |
| Caminhão | 0 | 1 | 0 | 308 | 5 | 7 | 321 |
| Carreta | 0 | 0 | 0 | 6 | 252 | 0 | 258 |
| Utilitários | 8 | 0 | 1 | 1 | 0 | 535 | 545 |
| Total Classificação | 300 | 240 | 254 | 317 | 258 | 549 | 1918 |

Tabela 8 - Percentuais de Classificação para o conjunto de testes, utilizando Rede Neural e 11 parâmetros extraídos do perfil magnético.

| | Carro | Moto | Ônibus | Caminhão | Carreta | Utilitários | Total |
|----------------------------------|-------|--------|--------|----------|---------|-------------|-------|
| Taxa de acerto (%) | 98,65 | 100,00 | 97,68 | 95,95 | 97,67 | 98,17 | 97,97 |
| Taxa Falsos Negativos (%) | 0,42 | 0,05 | 0,05 | 0,47 | 0,31 | 0,73 | 2,03 |

5.1.3 SEIS CATEGORIAS – DISTÂNCIA DE MAHALANOBIS

De forma a ser comparado com a classificação em seis categorias utilizando Rede Neural, são apresentados na Tabela 9 e na Tabela 10 os resultados de classificação utilizando três parâmetros e a distância de Mahalanobis.

Tabela 9 - Matriz de confusão utilizando Rede Neural e 11 parâmetros característicos do perfil magnético para classificação em seis categorias.

| CATEGORIA REAL | CLASSIFICAÇÃO REDE NEURAL | | | | | | Total Real |
|----------------------------|---------------------------|------|--------|----------|---------|-------------|------------|
| | Carro | Moto | Ônibus | Caminhão | Carreta | Utilitários | |
| Carro | 282 | 0 | 1 | 1 | 0 | 12 | 296 |
| Moto | 0 | 238 | 0 | 1 | 0 | 0 | 239 |
| Ônibus | 0 | 0 | 250 | 3 | 1 | 5 | 259 |
| Caminhão | 0 | 0 | 6 | 298 | 7 | 10 | 321 |
| Carreta | 0 | 0 | 5 | 2 | 251 | 0 | 258 |
| Utilitários | 13 | 0 | 1 | 2 | 0 | 529 | 545 |
| Total Classificação | 295 | 238 | 263 | 307 | 259 | 556 | 1918 |

Tabela 10 - Percentuais de Classificação para o conjunto de testes, utilizando distância de Mahalanobis, três parâmetros.

| | Carro | Moto | Ônibus | Caminhão | Carreta | Utilitários | Total |
|----------------------------------|-------|-------|--------|----------|---------|-------------|-------|
| Taxa de acerto (%) | 95,27 | 99,58 | 96,53 | 92,83 | 97,29 | 97,06 | 96,35 |
| Taxa Falsos Negativos (%) | 0,68 | 0,00 | 0,68 | 0,47 | 0,42 | 1,41 | 3,65 |

Conforme pode ser verificado, os índices de classificação individuais e geral são muito próximos aos obtidos pelo sistema utilizando rede neural com os mesmos três parâmetros. As taxas de falsos negativos foram superiores para as categorias, ônibus, caminhão, carro e carreta, para estas duas últimas classes isto foi

ocasionado pelo maior número de vans classificadas como carros e de caminhões classificados como carretas.

5.2 CLASSIFICAÇÃO EM OITO CATEGORIAS

Foi também proposto um sistema de classificação em 08 categorias: carro, moto, ônibus, caminhão, carreta, van, caminhonete e camioneta. As três últimas classes correspondem ao desmembramento da categoria de utilitários. O item 5.2.1 mostra os resultados dos testes utilizando rede neural com 11 parâmetros de entrada, enquanto que no item 5.2.2 são apresentados os resultados do sistema utilizando 8 redes neurais com saída binária, cada uma com 11 parâmetros de entrada. O item 5.2.3 apresenta os resultados do método da distância de Mahalanobis calculada a partir de 11 parâmetros e no item 5.2.4 calculada através de 3 parâmetros.

5.2.1 11 PARÂMETROS

A Tabela 11 apresenta os resultados na matriz de confusão, utilizando 11 parâmetros de entrada para a rede neural. As simulações do sistema classificador foram feitas com a base de parâmetros dos 1918 veículos. Nas linhas está registrada a quantidade de veículos referente à categoria de acordo com a imagem observada e nas colunas está registrada a classificação que o sistema atribuiu.

Tabela 11 - Matriz de confusão em oito categorias utilizando 11 parâmetros extraídos do perfil magnético.

| CATEGORIA REAL | CLASSIFICAÇÃO PELA REDE NEURAL | | | | | | | | Total Real |
|---------------------|--------------------------------|------|--------|----------|---------|-----|-------------|-----------|------------|
| | Carro | Moto | Ônibus | Caminhão | Carreta | Van | Caminhonete | Camioneta | |
| Carro | 289 | 1 | 0 | 0 | 0 | 1 | 1 | 4 | 296 |
| Moto | 0 | 239 | 0 | 0 | 0 | 0 | 0 | 0 | 239 |
| Ônibus | 0 | 1 | 250 | 4 | 2 | 2 | 0 | 0 | 259 |
| Caminhão | 0 | 1 | 3 | 306 | 5 | 0 | 6 | 0 | 321 |
| Carreta | 0 | 0 | 2 | 5 | 251 | 0 | 0 | 0 | 258 |
| Van | 4 | 0 | 2 | 0 | 0 | 102 | 29 | 27 | 164 |
| Caminhonete | 1 | 0 | 0 | 1 | 0 | 6 | 189 | 22 | 219 |
| Camioneta | 1 | 0 | 0 | 0 | 0 | 6 | 47 | 108 | 162 |
| Total Classificação | 295 | 242 | 257 | 316 | 258 | 117 | 272 | 161 | 1918 |

A Tabela 12 apresenta os índices de medição do desempenho do sistema.

Tabela 12 - Percentuais de Classificação para o conjunto de testes, uma rede neural 11-8-8.

| | Carro | Moto | Ônibus | Caminhão | Carreta | Van | Caminhonete | Camioneta | Total |
|----------------------------------|-------|-------|--------|----------|---------|-------|-------------|-----------|-------|
| Taxa de acerto (%) | 97,64 | 100,0 | 96,53 | 95,33 | 97,29% | 62,20 | 86,30 | 66,67 | 90,41 |
| Taxa Falsos Negativos (%) | 0,31 | 0,16 | 0,36 | 0,52 | 0,36 | 0,78 | 4,28 | 2,76 | 9,59 |

A partir da análise da Tabela 12, evidencia-se que:

- Apenas cinco caminhões foram classificados como carretas e apenas 5 carretas foram classificados como caminhões.
- Apenas quatro ônibus foram confundidos com caminhões
- As categorias carro, moto, ônibus, caminhões e carretas puderam ser separadas umas das outras com grande confiabilidade.
- Apenas uma camioneta, uma caminhonete e cinco vans foram confundidas com veículos de passeio e apenas 1 carro foi classificado como caminhonete e 1 classificado como van. O sistema foi capaz de separar com eficiência a categoria carro da categoria de utilitários (vans, caminhonetes e camionetas).

Entre as categorias de vans, camionetas e caminhonetes ocorreram os maiores erros na classificação, conforme já era previsto, devido ao fato de os perfis magnéticos entre estes tipos de veículos apresentarem muitas semelhanças. Ainda assim, os índices de acertos de classificação para estas categorias estão na mesma ordem de grandeza aos respectivos índices obtidos por Sun (2000) (71% para o total de veículos, sendo que caminhonetes e camionetas estavam agrupadas em uma mesma categoria e as vans em outra categoria. Um índice de 75% de acerto foi obtido por Oh e Ritchie (2007) para classificação de caminhonetes, camionetas e carros e de 58,3% para vans. Neste último, foram utilizados para testes apenas 12 veículos de cada categoria, sendo que o sistema foi implementado através de uma rede neural probabilística com esquema de decisão bayesiano. As variáveis de entrada foram comprimento magnético, amplitude, desvio padrão, parâmetro de forma e grau de simetria. Já em outro trabalho de Ritchie *et al* (2005) foram obtidos índices de classificação de 96,24% para carros, 61,58% para caminhonetes (total de 133 no teste), 51,34% para vans (total de 638) e 47,63% para camionetas (apenas

42 no teste). Foram utilizadas as mesmas variáveis de entrada do trabalho de Oh e Ritchie (2007), entretanto o sistema foi implementado através de árvore de decisão heurística.

O sistema de classificação proposto por Oh *et al* (2002) também utiliza uma rede neural com retropropagação de erro, utilizando como parâmetros de entrada a máxima amplitude do perfil, o comprimento magnético, o parâmetro de forma e a área sob a curva do perfil. Os veículos foram classificados em sete categorias tendo alcançado índice de classificação geral de 82,6%. O percentual de acertos na classificação para as categorias foram respectivamente: carros e minivans, 88,6%; camionetas, 74,3%; van e microônibus, 75%; caminhonetes, 75,7%; caminhão 85,4%; carreta, 100%; ônibus, 100%, sendo que para esta última classe apenas 10 veículos foram utilizados no teste.

5.2.2 1_N REDES NEURAI

A Tabela 13 e Tabela 14 apresentam os resultados dos testes do sistema de classificação implementado através de oito redes neurais, valor correspondente a quantidade de classes de veículos que se deseja classificar. Conforme descrito com maiores detalhes na seção 4.3, os vetores de entrada, constituídos pelas características extraídas do perfil magnético foram apresentados para cada rede neural de saída binária com apenas um bit, que indica se determinado veículo pertence ou não aquela classe específica. Foram utilizados os mesmos parâmetros do perfil e conjuntos de dados para treinamento, validação, e testes que o sistema com rede neural única.

Tabela 13 - Resultado absoluto da classificação em oito categorias utilizando 11 parâmetros extraídos do perfil magnético, implementada com oito redes neurais binárias.

| CATEGORIA REAL | CLASSIFICAÇÃO PELA REDE NEURAL | | | | | | | | Total Real |
|---------------------|--------------------------------|------|--------|----------|---------|-----|-------------|-----------|------------|
| | Carro | Moto | Ônibus | Caminhão | Carreta | Van | Caminhonete | Camioneta | |
| Carro | 291 | 2 | 0 | 0 | 0 | 0 | 2 | 1 | 296 |
| Moto | 0 | 239 | 0 | 0 | 0 | 0 | 0 | 0 | 239 |
| Ônibus | 0 | 1 | 249 | 0 | 0 | 5 | 4 | 0 | 259 |
| Caminhão | 0 | 0 | 1 | 302 | 5 | 4 | 8 | 1 | 321 |
| Carreta | 0 | 0 | 1 | 5 | 250 | 2 | 0 | 0 | 258 |
| Van | 4 | 0 | 10 | 1 | 0 | 109 | 26 | 14 | 164 |
| Caminhonete | 2 | 0 | 5 | 2 | 0 | 5 | 191 | 14 | 219 |
| Camioneta | 4 | 0 | 0 | 0 | 0 | 11 | 42 | 105 | 162 |
| Total Classificação | 301 | 242 | 266 | 310 | 255 | 136 | 273 | 135 | 1918 |

Tabela 14 - Percentuais de Classificação para o conjunto de testes com oito redes neurais 11-5-1.

| | Carro | Moto | Ônibus | Caminhão | Carreta | Van | Caminhonete | Camioneta | Total |
|----------------------------------|-------|------|--------|----------|---------|-------|-------------|-----------|-------|
| Taxa de acerto (%) | 98,31 | 100 | 96,14 | 94,08 | 96,90 | 66,46 | 87,21 | 64,81 | 90,51 |
| Taxa Falsos Negativos (%) | 0,52 | 0,16 | 0,89 | 0,42 | 0,26 | 1,41 | 4,28 | 1,56 | 9,49 |

O tempo para processamento dos dados é proporcional ao número de redes neurais utilizadas na topologia, que por sua vez depende do número de categorias que se deseja distinguir. Os resultados na classificação foram bastante similares aos obtidos pela implementação do sistema em um único perceptron multicamada (MLP), o que indica que mapeamento entrada-saída está bom, tendo sido adotado pelo processo de treinamento, pesos adequados para cada função de mapeamento. Apesar de o tempo de processamento ser maior do que o sistema com uma única rede, a divisão em múltiplas redes permite uma maior autonomia das redes individuais. Dessa forma, cada perceptron necessita de apenas cinco neurônios na camada oculta em relação ao modelo com uma única rede (com oito neurônios) para atingir índices de classificação semelhantes.

5.2.3 DISTÂNCIA DE MAHALANOBIS – 11 PARÂMETROS

São mostrados na Tabela 16 os resultados para o sistema classificador utilizando como medida de proximidade a distância de Mahalanobis calculada entre vetores com 11 parâmetros extraídos do perfil magnético. A Tabela 15 apresenta os resultados totais e quantificados de classificação, com os respectivos índices de classificação correta e falsos negativos.

Tabela 15 - Resultado absoluto da classificação em oito categorias utilizando distância de Mahalanobis e 11 parâmetros característicos do perfil magnético.

| CATEGORIA REAL | CLASSIFICAÇÃO PELA REDE NEURAL | | | | | | | | Total Real |
|-----------------|--------------------------------|------|--------|----------|---------|-----|-------------|-----------|------------|
| | Carro | Moto | Ônibus | Caminhão | Carreta | Van | Caminhonete | Camioneta | |
| Carro | 281 | 0 | 1 | 0 | 0 | 5 | 4 | 5 | 296 |
| Moto | 0 | 237 | 0 | 2 | 0 | 0 | 0 | 0 | 239 |
| Ônibus | 0 | 0 | 258 | 1 | 0 | 0 | 0 | 0 | 259 |
| Caminhão | 0 | 0 | 0 | 288 | 25 | 6 | 2 | 0 | 321 |
| Carreta | 0 | 0 | 2 | 0 | 256 | 0 | 0 | 0 | 258 |
| Van | 2 | 0 | 5 | 0 | 0 | 127 | 15 | 15 | 164 |

| | | | | | | | | | |
|----------------------------|-----|-----|-----|-----|-----|-----|-----|-----|------|
| Caminhonete | 1 | 0 | 0 | 0 | 0 | 82 | 110 | 26 | 219 |
| Camioneta | 3 | 0 | 0 | 0 | 0 | 82 | 18 | 59 | 162 |
| Total Classificação | 287 | 237 | 266 | 291 | 281 | 302 | 149 | 105 | 1918 |

Tabela 16 - Percentuais de Classificação para o conjunto de testes, utilizando distância de Mahalanobis e 11 param.

| | Carro | Moto | Ônibus | Caminhão | Carreta | Van | Caminhonete | Camioneta | Total |
|----------------------------------|--------------|-------------|---------------|-----------------|----------------|------------|--------------------|------------------|--------------|
| Taxa de acerto (%) | 94,93 | 99,16 | 99,61 | 89,72 | 99,22 | 77,44 | 50,23 | 36,42 | 84,25 |
| Taxa Falsos Negativos (%) | 0,31 | 0,00 | 0,42 | 0,16 | 1,30 | 9,12 | 2,03 | 2,40 | 15,75 |

O índice geral de classificação correta é praticamente o mesmo encontrado com o uso da rede neural e o mesmo número de parâmetros. Resultados superiores na classificação foram encontrados para ônibus (a categoria não apresentou nenhum veículo classificado erroneamente como carreta ou van), carreta (nenhum veículo da categoria foi classificado como caminhão) e van (o número de vans classificadas como camionetas reduziu de 29 para 15). Em compensação o uso da Distancia de Mahalanobis provocou uma queda no índice de classificação para as camionetas, tendo aumentado o número daquelas confundidas com vans o que contribui por sua vez para elevar o índice de falsos negativos para esta categoria. Considerando toda a classe de utilitários (vans, caminhonetes e camionetas) o percentual de classificação reduziu 5% em relação ao sistema utilizando distância euclidiana, ficando em torno de 55%.

5.2.4 DISTÂNCIA DE MAHALANOBIS – TRÊS PARÂMETROS

O sistema utilizando apenas três parâmetros apresentou praticamente os mesmos índices de classificação individual e total que o sistema utilizando 11 parâmetros, conforme pode ser visto na Tabela 17 e Tabela 18. As exceções ocorreram para a classe das vans, que apresentou índice inferior e para a classe das camionetas, com índice de classificação superior. Entretanto o grupo de utilitários apresentou praticamente o mesmo valor percentual de categorização correta (55%). O fato evidencia que somente três parâmetros são capazes de efetivamente realizar a separação entre as classes, os demais parâmetros acrescentados não agregam

informação ao sistema classificador por distância de Mahalanobis, sendo, portanto desnecessários, pois somente demandam maior tempo de processamento ao algoritmo.

Tabela 17 - Resultado absoluto da classificação em oito categorias utilizando distância de Mahalanobis e três parâmetros característicos do perfil magnético.

| CATEGORIA REAL | CLASSIFICAÇÃO PELA REDE NEURAL | | | | | | | | Total Real |
|---------------------|--------------------------------|------|--------|----------|---------|-----|-------------|-----------|------------|
| | Carro | Moto | Ônibus | Caminhão | Carreta | Van | Caminhonete | Camioneta | |
| Carro | 279 | 0 | 0 | 1 | 0 | 7 | 2 | 7 | 296 |
| Moto | 0 | 238 | 0 | 1 | 0 | 0 | 0 | 0 | 239 |
| Ônibus | 0 | 0 | 250 | 2 | 1 | 6 | 0 | 0 | 259 |
| Caminhão | 0 | 0 | 6 | 295 | 7 | 3 | 10 | 0 | 321 |
| Carreta | 0 | 0 | 5 | 2 | 251 | 0 | 0 | 0 | 258 |
| Van | 0 | 0 | 0 | 2 | 0 | 76 | 28 | 58 | 164 |
| Caminhonete | 4 | 0 | 0 | 0 | 0 | 23 | 115 | 77 | 219 |
| Camioneta | 3 | 0 | 0 | 0 | 0 | 13 | 37 | 109 | 162 |
| Total Classificação | 286 | 238 | 261 | 303 | 259 | 128 | 192 | 251 | 1918 |

Tabela 18 - Percentuais de Classificação para o conjunto de testes, utilizando distância de Mahalanobis, três parâmetros.

| | Carro | Moto | Ônibus | Caminhão | Carreta | Van | Caminhonete | Camioneta | Total |
|---------------------------|-------|-------|--------|----------|---------|-------|-------------|-----------|-------|
| Taxa de acerto (%) | 94,26 | 99,58 | 96,53 | 91,90 | 97,29 | 46,34 | 52,51 | 67,28 | 84,10 |
| Taxa Falsos Negativos (%) | 0,36 | 0,00 | 0,57 | 0,42 | 0,42 | 2,71 | 4,01 | 7,40 | 15,90 |

Para todos os casos de teste apresentados, envolvendo as oito categorias, é possível perceber que os índices para as classes de utilitários apresentam resultados não superiores a 60%, considerando o total para este grupo. O uso da Rede Neural MLP, para a classificação de somente utilitários apresentou índice de classificação bastante significativo, de praticamente 77%, chegando a mais de 80% para as caminhonetes. Foi possível verificar que o sistema que utiliza rede neural apresenta resultados na classificação geral 6% superior ao que utiliza distância de Mahalanobis, tanto com três quanto com 11 parâmetros de entrada.

5.3 CLASSIFICAÇÃO DE UTILITÁRIOS

As categorias caminhonetes, camionetas e vans, conforme já mencionado, apresentam perfis magnéticos com muitas similaridades. Em um sistema de classificação em oito categorias há ainda a possibilidade de alguns desses utilitários

serem confundidos com outras categorias o que pode diminuir ainda mais o desempenho do sistema

Desse modo, foram realizados testes com sistema para classificação somente de utilitários. Os testes foram contemplaram uso de Distância de Mahalanobis (item 5.3.1) e Rede Neural (item 5.3.2), ambos com 11 parâmetros de entrada. Não foram efetivados testes com três parâmetros, pois a análise dos respectivos histogramas mostrou que as variáveis possivelmente não permitiriam diferenciar as classes veiculares.

5.3.1 SOMENTE UTILITÁRIOS – DISTÂNCIA DE MAHALANOBIS

São apresentados na Tabela 19 os resultados para classificação utilizando distancia de Mahalanobis somente para as três classes de utilitários (van, caminhonete, camioneta), utilizando 11 parâmetros.

Tabela 19 - Resultado absoluto da classificação para as três categorias de utilitários, utilizando distância de Mahalanobis e 11 parâmetros característicos do perfil magnético.

| CATEGORIA REAL | CLASSIFICAÇÃO DIST. MAHALANOBIS | | | Total Real |
|--------------------------------|---------------------------------|-------------|-----------|---------------|
| | Van | Caminhonete | Camioneta | |
| Van | 150 | 6 | 8 | 164 |
| Caminhonete | 173 | 30 | 16 | 219 |
| Camioneta | 130 | 5 | 27 | 162 |
| Total Classificação | 453 | 41 | 51 | 545 |

Conforme pode ser observado na Tabela 20, os índices de classificação geral e de cada classe são bastante baixos, com exceção da categoria van (91,46%), que por sua vez também apresenta a maior taxa de falsos negativos, pelo fato de tanto caminhonetes como camionetas terem sido confundidas com esta categoria.

Tabela 20 - Percentuais de Classificação para o conjunto de testes, para classificação de utilitários utilizando distância de Mahalanobis de 11 parâmetros.

| | Van | Caminhonete | Camioneta | Total |
|----------------------------------|-------|-------------|-----------|-------|
| Taxa de acerto (%) | 91,46 | 13,70 | 16,67 | 37,98 |
| Taxa Falsos Negativos (%) | 55,60 | 2,02 | 4,40 | 62,02 |

5.3.2 SOMENTE UTILITÁRIOS – REDE NEURAL

Também foram realizados testes do sistema de classificação específico para a classe de utilitários, implementado com Rede Neural, utilizando os mesmos 11 parâmetros e oito neurônios na camada oculta.

Tabela 21 - Resultado absoluto da classificação para as três categorias de utilitários, utilizando Rede Neural MLP e 11 parâmetros característicos do perfil magnético.

| CATEGORIA REAL | CLASSIFICAÇÃO REDE NEURAL | | | Total Real |
|---------------------|---------------------------|-------------|-----------|------------|
| | Van | Caminhonete | Camioneta | |
| Van | 120 | 27 | 17 | 164 |
| Caminhonete | 15 | 176 | 28 | 219 |
| Camioneta | 11 | 28 | 123 | 162 |
| Total Classificação | 146 | 231 | 168 | 545 |

Tabela 22 - Percentuais de Classificação para o conjunto de testes, para classificação de utilitários Rede Neural MLP e 11 parâmetros do perfil magnético.

| | Van | Caminhonete | Camioneta | Total |
|---------------------------|-------|-------------|-----------|-------|
| Taxa de acerto (%) | 73,17 | 80,37 | 75,93 | 76,88 |
| Taxa Falsos Negativos (%) | 4,77 | 10,09 | 8,26 | 23,12 |

A Tabela 22 permite verificar que o uso da Rede Neural para a classificação de utilitários apresenta resultados superiores ao uso da Distância de Mahalanobis, dobrando praticamente o índice geral de classificação, o que evidencia a vantagem do método não linear para resolução do problema envolvendo perfis magnéticos muito semelhantes. O número de camionetas classificadas como caminhonetes, foi o mesmo de veículos desta última classe que foram confundidos com os da primeira (28 no total), mostrando que o sistema errou de forma simétrica. Considerando a grande similaridade entre as categorias, tal comportamento já era esperado, ocorrendo praticamente o mesmo fato para a taxa de falsos negativos (10,09% para caminhonetes e 8,26% para camionetas) a pequena diferença ocorreu por um maior número de vans ter sido classificada como caminhonete em relação a camionetas.

5.4 RESUMO DOS RESULTADOS

Os resultados dos testes para cada um dos casos simulados são mostrados na Tabela 23, sendo apresentados os índices de acerto geral de classificação para cada caso de teste.

Tabela 23 - Índices de acertos na classificação para as diferentes simulações.

| Parâmetros de Entrada | Técnica Utilizada | Número de Classes | Classificação Correta - Geral |
|------------------------------|----------------------------------|--------------------------|--------------------------------------|
| 3 | Distância de Mahalanobis | 06 | 96,92% |
| 11 | Rede Neural MLP | 06 | 97,97% |
| 3 | Distância de Mahalanobis | 06 | 96,35% |
| 11 | Distância de Mahalanobis | 03 | 37,98% |
| 11 | Rede Neural MLP | 03 | 76,88% |
| 11 | Rede Neural MLP | 08 | 90,41% |
| 11 | 08 Redes Neurais MLP Binárias | 08 | 90,51% |
| Pontos do Perfil Magnético | Distância Euclidiana | 08 | 71,27% |
| 11 | Distância Euclidiana | 08 | 46,25% |
| 3 | Distância Euclidiana | 08 | 54,90% |
| 11 | Distância Euclidiana Normalizada | 08 | 84,36% |
| 3 | Distância Euclidiana Normalizada | 08 | 84,31% |
| 11 | Distância de Mahalanobis | 08 | 84,25% |
| 3 | Distância de Mahalanobis | 08 | 84,10% |

Observando a Tabela 23, verifica-se que a utilização de apenas três parâmetros de entrada apresenta bons resultados para classificação em seis categorias, tanto utilizando distância de Mahalanobis como Rede Neural, dessa forma, devido a questões de maior simplicidade na implementação, é mais interessante que para este sistema seja utilizada o método linear e não a técnica de Inteligência Artificial. Por outro lado, mesmo utilizando 11 parâmetros, a Distância de Mahalanobis não foi capaz de separar as categorias de utilitários de caminhonetes, camionetas e vans. Para esta segunda etapa de classificação, é possível obter

resultados melhores através de Rede Neural utilizando 11 coeficientes do perfil magnético como neurônios de entrada, tendo sido alcançados resultados gerais em torno de 80%. Desse modo, pode ser proposta uma topologia para o sistema de classificação utilizando a Distância de Mahalanobis e três parâmetros de modo a agrupar os veículos em seis categorias e então classificar o grupo de utilitários com o uso de Rede Neural em vans, caminhonetes e camionetas. Considerando a composição das técnicas, os resultados totais são apresentados na Tabela 24, sendo o índice de classificação total atingido de 90,62%, com o menor índice atingido para a categoria Van, que ficou em 73,17%.

Tabela 24 - Percentuais de Classificação para a topologia do Sistema completo de classificação utilizando distância de Mahalanobis com três parâmetros e Rede Neural com 11 parâmetros.

| | Carro | Moto | Ônibus | Caminhão | Carreta | Van | Caminhonete | Camioneta | Total |
|---------------------------|-------|-------|--------|----------|---------|-------|-------------|-----------|-------|
| Taxa de acerto (%) | 94,26 | 99,58 | 96,53 | 91,90 | 97,29 | 73,17 | 80,37 | 75,93 | 90,62 |

Os resultados mostrados na Tabela 24 são superiores aos do sistema utilizando oito redes neurais binárias, tendo sido superiores também para as categorias caminhonete e camioneta e inferiores para a de utilitários.

6 CONCLUSÃO

Neste trabalho foi apresentado um sistema para classificação de veículos em oito categorias cujas variáveis de entrada foram extraídas a partir dos perfis magnéticos dos veículos. Os testes foram realizados utilizando diferentes técnicas de classificação alterando a quantidade de variáveis de entrada para o sistema. Foi utilizada uma base de dados com 3906 perfis magnéticos, com quantidades semelhantes para cada categoria o que representa uma quantidade de veículos maior e melhor distribuída em cada classe em relação a outros trabalhos publicados. O sistema alcançou resultados de 90% para classificação em oito categorias e 97% para seis categorias.

Foram realizadas comparações entre o sistema de classificação através de redes neurais e através de métodos lineares de medidas de similaridade, tais como Distância de Mahalanobis e Distância Euclidiana. Para a classificação em seis categorias, a rede MLP e a Distância de Mahalanobis apresentaram resultados semelhantes (98% e 97%, respectivamente). O uso da rede neural apresenta vantagem para classificação em oito categorias, permitindo diferenciar os veículos dentro do grupo de utilitários com resultado geral de classificação de 90%, contra 84% apresentado pela distância de Mahalanobis. A maior capacidade para diferenciação de utilitários é notória na comparação de resultados para classificação somente de utilitários. Neste caso, o sistema utilizando rede neural alcançou o índice de 77%, contra 38% apresentado pela Distância de Mahalanobis.

Foi proposta a combinação de diversas técnicas para se obter os melhores resultados na classificação. Desse modo, em uma primeira etapa de classificação, pode ser utilizada a distância de Mahalanobis com três parâmetros de entrada selecionados a partir da capacidade de diferenciação entre classes para classificação em seis categorias. Para a segunda etapa, pode ser utilizada rede neural perceptron multicamada com oito neurônios na camada escondida e 11 parâmetros de entrada para classificação somente entre as categorias de utilitários (caminhonete, camioneta e van). Ao combinar os resultados, o índice de classificação geral alcançado é de 90%. Os índices de classificação para carros, motos, ônibus, caminhões, carretas, vans, caminhonetes, e camionetas foram de

94%, 100%, 97%, 92%, 97%, 73%, 80% e 76%, respectivamente. Com exceção das classes de utilitários (vans, camionetas e caminhonetes), os demais tipos de veículos apresentaram alta taxa de classificação por apresentarem características extraídas do perfil magnéticos bastante distinguíveis. Ainda assim a classificação em duas etapas apresenta resultados superiores para as classes vans e caminhonetes em relação ao sistema que utiliza rede MLP única para classificação em oito categorias.

Os resultados apresentados mostram que as Redes Neurais podem ser tão eficientes ou mais que os métodos de classificação linear, porém requerem ajustes mais complexos de forma a alcançar os melhores resultados. Mesmo assim, as redes neurais podem ser consideradas ferramentas muito úteis para a resolução do problema de classificar veículos com perfis magnéticos muito semelhantes, como caminhonetes e camionetas, extraídos a partir de sensores indutivos comuns, que não permitem capturar informações referentes à composição de eixos e rodas. Deste modo, a classificação de veículos proposta pelo sistema poderia contribuir com informações a serem utilizadas para aplicações em transporte, tais como a fiscalização de faixas exclusivas de veículos ou o monitoramento de categorias de veículos distintas em faixas de velocidades distintas.

Trabalhos futuros podem mostrar uma melhora no método para escolha dos parâmetros extraídos do perfil magnético, incorporando outras técnicas de inteligência artificial como algoritmos genéticos. O uso de lógica nebulosa pode também ser estudado a fim de auxiliar na escolha da melhor arquitetura de rede neural a ser utilizada.

Podem também ser realizados testes no sistema de classificação, considerando um número maior de categorias, subdividindo-se, por exemplo, as classes de caminhões e carretas, conforme o tipo de carroceria ou o comprimento apresentado.

Por fim, podem-se utilizar as técnicas apresentadas neste trabalho em conjunto com outros elementos sensores baseados em imagem para melhorar os índices de classificação veicular.

REFERÊNCIAS BIBLIOGRÁFICAS

ACKLAM, P. J.. **MATLAB array manipulation tips and tricks**. Statistics Division Department of Mathematics University of Oslo Norway, 2000. Disponível em: <http://www.ee.columbia.edu/~marios/matlab/Matlab%20array%20manipulation%20tips%20and%20tricks.pdf>

ANDREOTTI, M. T.. **Sensoriamento Indutivo para Veículos Automotores**. Dissertação de Mestrado apresentada ao CPGEI, UTFPR, Curitiba, 2001.

BARBOSA, H. M.; BRAGA, C. M. P.; JOTA, F. G.; MAGALHÃES, D. J. A. V.; GOUVÊA, R. G.; DOURADO, D. A. F.; CARVALHO, J. L. P.; EULETÉRIO, J. C.; MENDES, V. C.. **Sistema de Identificação de Veículos por Meio de Laços de Indução: Um projeto Integrado de Ensino e Desenvolvimento Tecnológico**. Anais eletrônicos do XVIII Congresso Nacional de Pesquisa e Ensino em Transportes, ANPET, 2004.

BEALE, M. H.; HAGAN, M. T.; DEMUTH, H. B.. **Neural Network Toolbox - User's Guide – R2011b**. Disponível em: http://www.mathworks.com/help/pdf_doc/nnet/nnet_ug.pdf.

CALIXTO, S. A.. **Classificação de Veículos Através de Sistemas Fuzzy**. Dissertação de Mestrado apresentado ao CPGEI, UTFPR, Curitiba, 2006.

CHEUNG, S.Y.; COLERI, S.; DUNDAR, B.; GANESH, S.; TAN, C.W.; VARAIYA, P.. **Traffic measurement and vehicle classification with a single magnetic sensor**. In Transportation Research Record: Journal of the Transportation Research Board, No. 1917, TRB, National Research Council, Washington, D.C., p. 173-181, 2004.

DIAS, F. G.. **Uma Proposta Evolutiva para um Classificador de Distância Mínima**. Notas de aula da disciplina IA 707 – Computação Evolutiva - Prof. Dr. Fernando J. Von Zuben, junho, 2004.

DWINNELL, W.. **Data Mining in Matlab – Mahalanobis Distance**. Disponível em <http://matlabdatamining.blogspot.com/2006/11/mahalanobis-distance.html>

FAUSETT, L.V. **Fundamentals of neural networks**. Ed. Prentice-Hall, 1994.

FERREIRA, V. H.. **Introdução às Redes Neurais Artificiais – TE- 803 – Inteligência Artificial Aplicada**. UFPR – Aula 2 – Notas de Aula – Junho, 2008.

FHWA, **Traffic Detector Handbook**, FHWA, Publication No. FHWA-IP-90-002, 1990 Disponível em: <http://www.fhwa.dot.gov/tfhrc/safety/pubs/lp90002/IP90002.pdf>.

FORESEE, F. D.; HAGAN, M. T.. **Gauss-Newton Approximation to Bayesian Regularization**. International Joint Conference on Neural Networks, p. 1930-1935, 1997.

GAJDA, J., SROKA, R.. **The vehicle classification by parametric identification of measured signals**. Proceedings of XVI IMEKO World Congress, v. IX, p. 199-204, Viena, 2000.

GAJDA, J.; SROKA, R.; STENCEL, M. et al. **A vehicle classification based on inductive loop detectors**. Proceedings of IEEE IMTC. p. 460-464, Budapest. May 21-23, 2001.

GONÇALVES, R. M.; COELHO, L. S.; KRUEGER, C. P.; HECK, B.. **Modelagem preditiva de linha de Costa Utilizando Redes Neurais Artificiais**. Boletim. Ciências. Geodésicas., seção. Artigos, Curitiba, v. 16, no 3, p.420-444, jul-set, 2010

GUPTA, S.; MASOUD, O.; MARTIN, R.; PAPANIKOLOPOULOS, N.P.,. **Detection and classification of vehicles**, IEEE Transactions on Intelligent Transportation Systems, vol. 3(1), p. 37-47, 2002.

HAGAN, M. T.; MENHAJ, M. B..**Training feedforward networks with the Marquardt algorithm**. IEE Transactions on Neural Networks, v. 5, n. 6., p. 989-993, 1994

HARLOW, C.; PENG, S.,. **Automatic vehicle classification with range sensors**. Transportation Research Part C: Emerging Technology, vol. 9, issue 4, p. 231-247, 2001.

HAYKIN, S. **Neural Networks – A comprehensive foundation**. McMaster University Hamilton, Ontario, Canada, Pearson Education,. 823 p., 1999

HEIDEMANN, J.; SILVA, F.; WANG, X.; SURE-SE **Sensors for Unplanned Roadway Events--Simulation and Evaluation Draft Final Report** METRANS Project 04-08, 2004.

HILLIARD, S.R.; HILLIARD, G. W. **U. S. Patent nº 6.342.845**, 29 de janeiro de 2002.

JENG, S.; RITCHIE S.G.. **Real-time Vehicle Classification using Inductive Loop Signatue Data**. Proceedings of the 87th Annual Meeting of the Transportation Research Board, Washington, D.C, 2008.

KI, Y. K.; BAIK, D. K.. **Vehicle-Classification Algorithm for Single-Loop Detectors Using Neural Networks**. IEEE Transactions on Vehicular Technology, Vol. 55, No. 6, Novembro, 2006

LU, Y. H.; SU Y.; MALDAGUE, X.. **Vehicle Classification Using Infrared Image Analysis**, Journal of Transportation Engineering. vol. 118, no. 2, p. 223-240, 1992.

MACKAY, D. J.. C. **Bayesian interpolation**, *Neural Computation*, v. 4, p. 415-447, 1992.

MAGALHÃES, H. A.. **Análise em Alta Resolução de Perfis Magnéticos de Sensores a Laço Indutivo e Metodologia de Fusão com Características de Imagem para Classificação de Veículos**. Tese (Doutorado em Engenharia Elétrica apresentada a UFMG, Belo Horizonte, 2008.

MANLY, B. F. J.. **Multivariate statistical methods: a primer**. London: Chapman and Hall, 1986.

NISHIMOTO, R. E.. **Novas Geometrias de Laços Indutivos**. Dissertação de mestrado apresentada ao CPGEI, UTFPR, Curitiba, 2006.

NOORALAHYAN, A. Y.; DOUGHERTY, M.; MCKEOWN, D.; KIRBY, H.R.; 1997. **A field trial of acoustic signature analysis for vehicle classification**. *Transportation Research Part C: Emerging Technology*, vol. 5, issues 3-4, p. 165-177, 1997.

OH, C.; RITCHIE, S.; STEPHEN G.; JENG, S.. Anonymous **Vehicle Reidentification Using Heterogeneous Detection Systems**. *IEEE Transactions on Intelligent Transportation System*, 8(3):460- 9, September, 2007.

OH, C.; RITCHIE, S.G.. **Recognizing vehicle classification information from blade sensor signature**. *Pattern Recognition Letters*, vol. 28, issue 9, 2007, p. 1041-1049, 2007.

OH, S., RITCHIE, S.; STEPHEN G., OH, C., **Real Time Traffic Measurement from Single Loop Inductive Signatures**. 81st Annual Meeting of the Transportation Research Board, Washington, D. C., January, 2002.

OLIVEIRA H. A.; BARBOSA, F. R.; ALMEIDA, O. M.; BRAGA, A. P. S.. **Reconhecimento de Porte de Veículos com Análise de Perfil Magnético com Sensores Indutivos Instalados na Via de Trânsito Utilizando Redes Neurais Artificiais**. XIII Congresso Brasileiro de Automática, p. 3568-3574, Setembro 2010.

PARENTE, E. P.. **Tomografia de susceptibilidade magnética com magnetômetro supercondutor SQUID**. Tese de doutorado apresentada ao Departamento de Engenharia Elétrica, PUC-RJ. Dezembro, 1996.

PURSULA, M.; KOSONEN I.. **Microprocessor and PC-based vehicle classification equipments using inductive loops**. *Proceedings of the Second International Publication Number 299*, London. February 7-9, p 24-28, 1989.

PURSULA, M.; PIKKARAINEN, P.;. **A neural network approach to vehicle classification with double induction loops**. *Proceedings of the Second International Publication Number 299*, London. February 7-9. Pg 24-28, 1989.

RITCHIE, S.; STEPHEN G.; PARK, S.; OH, C.; JENG, S.; TOK, A.. **Anonymous Vehicle Tracking for Real-Time Freeway and Arterial Street Performance Measurement**. California PATH Research Report UCB-ITS-PRR-2005-9, Institute of Transportation Studies, University of California, Irvine, CA, USA, March, 2005a.

RITCHIE, S.; STEPHEN, G.; PARK, S.; OH, C.; JENG, S.; TOK, A.. **Field Investigation of Advanced Vehicle Reidentification Techniques and Detector Technologies – Phase 2**. California PATH Research Report UCB-ITS-PRR-2005-8, Institute of Transportation Studies, University of California, Irvine, CA, USA, March, 2005b.

RITCHIE, S.; STEPHEN, G.; PARK, S.; OH, C.; JENG, S.; TOK, A.; PARK, S.. **Corridor Deployment and Investigation of Anonymous Vehicle Tracking for Real-Time Traffic Performance Measurement**. California PATH Research Report UCB-ITS-PRR-2008-23, Institute of Transportation Studies, University of California, Irvine, CA, USA, Outubro, 2008.

RÜNCOS, R. A. E.. **Reconstrução da distribuição bidimensional de condutividade pela desconvolução da perturbação magnética**. Relatório apresentado a Coordenadoria de Iniciação Científica e Integração Acadêmica, UFPR. Julho, 2007.

SHIN, P.; JASSO, H.; TILAK, S.; COTOFANA, N.. Fountain, T.. **Automatic Vehicle Type Classification using Strain Gauge Sensors**. Proceedings of the Fifth IEEE International Conference on Pervasive Computing and Communications Workshops, p. 425-428, 2007.

SUN, C.. **An Investigation in the use of inductive loop signatures for vehicle classification**. Califórnia Path Research Report, UCB-ITS-PRR-2000-4, Berkeley, Março, 2000.

SUN, C.; RITCHIE, S. G.; OH, S.. **Inductive Classifying Artificial Network for Vehicle Type Categorization**. Computer-Aided Civil and Infrastructure Engineering, vol.18, No 3, p. 161-172, 2003.

TOK, A. Y. C. A. **Commercial Vehicle Classification System using Advanced Inductive Loop Technology**. Tese de Doutorado. UNIVERSITY OF CALIFORNIA IRVINE, 2008.

VICINI, L.. **Análise multivariada da teoria à prática**. Monografia apresentada a UFRS, 2005.

WINANDY, C. E.; FLHO, E. B.; BENT, L. V.. **Algoritmos para Aprendizagem Supervisionada**. CT 215 – Inteligência Artificial. Seminários, 2007.

ANEXO I

DISTRIBUIÇÃO ESTATÍSTICA DOS PARÂMETROS EXTRAÍDOS DO PERFIL MAGNÉTICO PARA A BASE DE DADOS DE VEÍCULOS

6.1 AMPLITUDE MÁXIMA

A Figura 16 mostra a distribuição da amplitude máxima entre as oito categorias.




Figura 16 - Distribuição da Amplitude Máxima para as oito categorias.

O parâmetro permite a separação do grupo formado por carros e ônibus por aquele formado por carretas e caminhões. As motos aparecem em um grupo totalmente separado, conforme esperado, devido a sua pequena composição metálica. Valores intermediários são apresentados por vans, caminhonetes e caminhonetes (entre 1000 e 2000).

6.2 VALOR MÉDIO

A Figura 17 mostra a distribuição do valor médio entre as oito categorias.




Figura 17 - Valor médio distribuído entre as oito categorias.

Para o parâmetro valor médio evidencia-se a diferenciação da categoria moto. As variações mais acentuadas ocorrem para as categorias de carros e ônibus e os menores valores para carretas e caminhões. Já camionetas, caminhonetes e vans apresentam valores intermediários.

6.3 NÚMERO DE PICOS

A Figura 18 mostra a distribuição do número de picos para as oito categorias.




Figura 18 - Distribuições do número de picos para as oito categorias.

Nota-se um grande número de inversões nos perfis magnéticos de carretas e ônibus.

6.4 VALOR MÉDIO DE PICOS

A Figura 19 mostra a distribuição do valor médio de picos entre as oito categorias.




Figura 19 - Distribuição do valor médio de picos entre as oito categorias

É possível verificar que categorias carretas e ônibus apresentam maiores valores médios de picos. Este parâmetro permite pequena separação entre ônibus e caminhões/carretas.

6.5 VARIÂNCIA NORMALIZADA

A Figura 20 mostra a distribuição da variância normalizada entre as 08 categorias.




Figura 20 - Distribuição estatística da variância normalizada para as oito categorias

Os histogramas de variância permitem verificar a separação da categoria carro das demais. Ônibus, caminhonetes, camionetas e vans apresentam valores intermediários, caminhões e carretas apresentam os menores valores.

6.6 TAXA DE SUBIDA

A Figura 21 mostra a distribuição da variância normalizada entre as oito categorias.




Figura 21 - Distribuição estatística da taxa de subida normalizada para as oito categorias

É notório que taxa de subida normalizada permite a separação entre carros e caminhonetes/camionetas/vans, permitindo também a diferenciação entre carretas e ônibus.

6.7 GRAU DE SIMETRIA

A Figura 22 mostra a distribuição do grau de simetria entre as oito categorias.




Figura 22 - Distribuição estatística do Grau de Simetria para as oito categorias.

O grau de simetria permite a importante separação entre camionetas (maiores valores) de caminhonetes (menores valores).

6.8 MEDIANA

A Figura 23 mostra a distribuição da mediana entre as oito categorias.




Figura 23 - Distribuição estatística da Mediana para as oito categorias.

Juntamente com o grau de simetria, a mediana permite a separação entre camionetas (maiores valores) de caminhonetes (menores valores).

6.9 NÚMERO DE AMOSTRAS DE ALTA AMPLITUDE

A Figura 24 mostra a distribuição do NHM entre as oito categorias.




Figura 24 – O número de amostras de alta amplitude (NHM) possibilita uma importante separação das vans em relação a caminhonetes e camionetas.

6.10 PARÂMETRO DE FORMA

A Figura 25 mostra a distribuição do Parâmetro de Forma entre as oito categorias.




Figura 25 - Distribuição estatística do Parâmetro de Forma para as oito categorias.

Conforme se pode verificar no histograma da Figura 25, o parâmetro de forma permite separar com maior facilidade o grupo das vans, (menores valores) do

grupo de camionetas e carros. As demais classes apresentam sobreposição de histogramas o que dificulta a distinção entre as mesmas ao utilizar este parâmetro.

ANEXO II

COMPARAÇÃO ENTRE PERFIS CARACTERÍSTICOS

Além da análise dos histogramas de cada parâmetro extraído dos perfis magnéticos das diferentes classes de veículos, é possível realizar a análise comparativa entre os perfis característicos de cada categoria, conforme descrito nesta seção.

Utilizando a mesma base de dados de perfis magnéticos, já separados por categoria e eliminados os casos atípicos já citados anteriormente, procedem-se a normalização em relação ao eixo das ordenadas (amplitude). O primeiro passo foi calcular a variação absoluta de cada perfil magnético, subtraindo o valor correspondente ao estado estacionário do laço no instante da captura.

Após esta etapa são removidos os pontos desnecessários à análise, isto é as 25 amostras anteriores à detecção do veículo, e as 20 posteriores a desdetecção.

O próximo passo consiste em normalizar os perfis na escala do tempo. Como o sistema de aquisição possui taxa de amostragem constante e igual a 1 kHz, a quantidade de pontos capturados varia de acordo com o comprimento e a velocidade dos veículos. Quanto maior o veículo ou menor sua velocidade, maior será o número de pontos capturados. A normalização temporal consiste em eliminar a dependência dos pontos do perfil em relação ao tempo, para isto basta multiplicar os pontos do vetor tempo pela velocidade.


Finalmente é calculada a média dos perfis já normalizados, gerando o perfil característico para cada categoria veicular.

A Figura 26 mostra os perfis normalizados no eixo do tempo e da amplitude para cada classe de veículos e respectivo perfil característico, obtido a partir da média dos perfis normalizados.


Conforme pode ser observado, os perfis magnéticos da categoria Carreta podem ser separados em dois grandes grupos de acordo com as peculiaridades apresentadas em seu perfil magnético. As carretas caracterizadas como do Tipo 1 apresentam peculiaridades na carroceria e cabine que geram um perfil magnético de maior amplitude, enquanto as carretas do Tipo 2 apresentam menor amplitude no perfil magnético.

Na Figura 26 os perfis característicos de cada categoria são apresentados em conjunto, considerando o agrupamento de todas as carretas em uma mesma classe.


a)




b)




c)




d)




e)



f)



g)



h)




Figura 26 - a) Carro, b) Ônibus, c) Moto, d) Caminhão, e) Van, f) Caminhonete, g) Camionetas, h) Carreta.



(a)



(b)





Figura 27 - Perfis magnéticos e perfil característico do grupo de carretas do tipo 1 (a) e do tipo 2 (b). As carretas do Tipo 1 têm carroceria com predomínio de material não metálico, e portanto, a amplitude máxima do perfil é determinada pela parte do cavalo mecânico, sendo atingido o máximo enquanto esta parte passa por sobre os sensores. Já as carretas do Tipo 2, apresentam carroceria com grande composição metálica, como é o caso da carreta “cegonha”. Assim a amplitude máxima do perfil é maior, sendo o valor mínimo atingido no momento da passagem da carroceria por sobre o sensor, pelo fato de esta parte encontrar-se mais baixa em relação ao asfalto.